

日本国特許庁  
JAPAN PATENT OFFICE

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出願年月日      2003年  3月28日  
Date of Application:

出願番号      特願2003-090360  
Application Number:  
[ST. 10/C]:      [JP2003-090360]


出願人      株式会社日立製作所  
Applicant(s):

U.S. Appln. Filed 8-25-03  
Inventor: K. mogi et al  
mattingly Stanger + Matur  
Docket NIT-392

2003年  8月13日

特許庁長官  
Commissioner,  
Japan Patent Office

今井康夫



【書類名】 特許願  
【整理番号】 NT03P0247  
【提出日】 平成15年 3月28日  
【あて先】 特許庁長官 殿  
【国際特許分類】 G06F 12/00  
【発明者】  
【住所又は居所】 神奈川県川崎市麻生区王禅寺1099番地 株式会社日立製作所 システム開発研究所内  
【氏名】 茂木 和彦  
【発明者】  
【住所又は居所】 神奈川県川崎市麻生区王禅寺1099番地 株式会社日立製作所 システム開発研究所内  
【氏名】 西川 記史  
【発明者】  
【住所又は居所】 神奈川県川崎市麻生区王禅寺1099番地 株式会社日立製作所 システム開発研究所内  
【氏名】 江口 賢哲  
【特許出願人】  
【識別番号】 000005108  
【氏名又は名称】 株式会社日立製作所  
【代理人】  
【識別番号】 100068504  
【弁理士】  
【氏名又は名称】 小川 勝男  
【電話番号】 03-3661-0071

**【選任した代理人】****【識別番号】** 100086656**【弁理士】****【氏名又は名称】** 田中 恭助**【電話番号】** 03-3661-0071**【選任した代理人】****【識別番号】** 100094352**【弁理士】****【氏名又は名称】** 佐々木 孝**【電話番号】** 03-3661-0071**【手数料の表示】****【予納台帳番号】** 081423**【納付金額】** 21,000円**【提出物件の目録】****【物件名】** 明細書 1**【物件名】** 図面 1**【物件名】** 要約書 1**【プルーフの要否】** 要

【書類名】 明細書

【発明の名称】

記憶装置のキャッシュ管理方法

【特許請求の範囲】

【請求項 1】

データベース管理システムが動作する計算機と、キャッシュを備えかつ前記データベース管理システムが管理するデータベースのデータを格納する記憶装置と、該計算機及び記憶装置を管理する管理装置とが夫々ネットワークを介して接続されてなるデータ処理システムにおけるキャッシュ量設定のための装置であって、

該データベース管理システムで実行される処理の内容に関する情報を取得する手段と、

該計算機及び該記憶装置からデータのマッピングに関する情報を取得する手段と、

該取得情報を用いて前記記憶装置のキャッシュ量設定案を作成する手段と、該記憶装置に対してキャッシュ量設定案に従ってキャッシュ量の設定を指示する手段とを有することを特徴とするキャッシュ量設定のための装置。

【請求項 2】

前記夫々の手段は、管理装置内に備えられるシステム管理プログラムによって実現される機能であることを特徴とする請求項 1 記載の装置。

【請求項 3】

前記計算機と前記記憶装置に接続され、両者間のデータの転送を制御する記憶制御手段と、

該記憶制御手段において該データベースのデータに対するマッピングを規定するマッピング手段と、

該マッピング手段からデータベースのデータのマッピングに関する情報を取得する手段を有することを特徴とする請求項 1 記載の装置。

【請求項 4】

前記夫々の手段は、前記計算機、前記記憶装置、又は前記記憶制御手段内で実

現される機能であることを特徴とする請求項1又は3記載の装置。

#### 【請求項5】

前記管理装置は、前記データベース管理システムで実行される前記処理の内容に関する情報として、前記処理で実行されるSQL文と、前記SQL文が実行される期待回数とを取得する手段を有することを特徴とする請求項1記載の装置。

#### 【請求項6】

前記管理装置が、前記データベース管理システムで実行される前記処理の内容に関する情報として、更に、前記処理が実行される比率を取得する手段を有することを特徴とする請求項5記載の装置。

#### 【請求項7】

前記管理装置は、前記取得情報として、更に、前記データベース管理システムの異常終了後の処理の再実行時の性能に関する情報と、前記データベース管理システムの異常終了後の処理の再実行時間設定に関する情報を取得する手段と、

前記記憶装置の前記キャッシュ量設定案として、前期データベース管理システムが outputするログに対するキャッシュ量の設定案を作成する手段とを有することを特徴とする請求項2又は6記載の装置。

#### 【請求項8】

前記管理装置は、前記データベース管理システムで実行される前記処理の内容に関する情報として、更に、前記処理が利用するデータのデータ量に関する情報と、前記処理が利用するデータへのアクセス分布に関する情報と、前記データベース管理システムと前記記憶装置で利用可能なキャッシュ量に関する情報を取得する手段と、

前記記憶装置の前記キャッシュ量設定案として、前期データベース管理システムが管理するデータである表や索引のキャッシュ量の設定案を作成する手段とを有することを特徴とする請求項2又は7記載の装置。

#### 【請求項9】

前記記憶装置は、前記キャッシュのアクセスに関する稼動統計情報を取得する手段を有すると共に、前記データベース管理システムは、該データベース管理システムが管理する表・索引を利用する際の待ち発生に関する稼動統計情報を取得

する手段とを有し、

前記管理装置は、前記取得情報として、更に、前記キャッシュアクセスの稼動統計情報と前記表・索引を利用する際の待ち発生に関する稼動統計情報を取得する手段と、前記記憶装置の前記キャッシュ量設定案として、前記データベース管理システムが管理する表や索引のキャッシュ量の設定の変更案を作成する手段とを有することを特徴とする請求項1又は5記載の装置。

#### 【請求項10】

前記管理装置は、前記データベース管理システムで実行される前記処理の内容に関する情報として、前記処理における前記データベース管理システムが管理するデータである表・索引への期待データページアクセス数を取得する手段を有することを特徴とする請求項1記載の装置。

#### 【請求項11】

前記管理装置は、前記データベース管理システムで実行される前記処理の内容に関する情報として、更に、前記処理が実行される比率と、前記処理が利用するデータのデータ量に関する情報と、前記処理が利用するデータへのアクセス分布に関する情報と、前記データベース管理システムと前記記憶装置で利用可能なキャッシュ量に関する情報を取得する手段と、

前記記憶装置の前記キャッシュ量設定案として、前期データベース管理システムが管理するデータである表や索引のキャッシュ量の設定案を作成する手段と、を有することを特徴とする請求項10記載の装置。

#### 【請求項12】

前記記憶装置は、前記キャッシュのアクセスに関する稼動統計情報を取得する手段を有すると共に、前記データベース管理システムは、該データベース管理システムが管理する前記表・索引を利用する際の待ち発生に関する稼動統計情報を取得する手段とを有し、

前記管理装置は、前記取得情報として、更に、前記キャッシュアクセスの稼動統計情報と前記表・索引を利用する際の待ち発生に関する稼動統計情報を取得する手段と、前期データベース管理システムが管理する表や索引のキャッシュ量の設定を変更する案を作成する手段とを有することを特徴とする請求項10記載

の装置。

#### 【請求項13】

データベース管理システムが実行される計算機と、該データベース管理システムにより管理されてデータを記憶するデータベース、及びデータベースのデータを一時的に格納するデータキャッシュを有する記憶装置とを含むデータ処理システムにおいて実行されるキャッシュの量を設定するためのプログラムであって、該データベース管理システムで実行される処理の内容に関する情報を取得する手段と、

該計算機及び該記憶装置からデータのマッピングに関する情報を取得する手段と、

取得された情報を用いて該記憶装置のキャッシュ量を設定する案を作成する手段と、

該記憶装置に対してキャッシュ量の設定案に従ってキャッシュ量の設定を指示する手段とを有することを特徴とするキャッシュ量を設定するためのプログラム。

#### 【請求項14】

データを記憶するディスク装置、及び該ディスク装置に記憶されるデータの少なくとも一部を一時的に記憶するデータキャッシュを有する記憶装置と、該記憶装置に対するデータ記憶の管理を行うデータベース管理システム(DBMS)プログラムが実行されてデータ処理を行う計算機と、該計算機及び該記憶装置を監視、管理するためのシステム管理プログラムを備える管理用の装置とが夫々ネットワークを介して接続されるデータ処理システムにおける該データキャッシュの最適な管理方法であって、

処理設計情報を参照して、Re-Run時における処理可能な処理の最大処理件数を求めるステップと、

各処理からINSERT/UPDATEを実行するSQL文と、SQL文の期待回数を求めるステップと、

該INSERT/UPDATEを実行するSQL文から出力されるログの最大データ量を求めるステップと、

ログの最大データ量から各処理当りのログのデータ量を計算するステップと、

各処理あたりのログのデータ量と、Re-Run時に処理可能な最大処理件数に基づいて必要なログの量を見積るステップと、

Re-Run時に必要以上のログ量がデータキャッシュに存在するようにキャッシュの量を求めるステップと、

この求められたキャッシュの量に従ってキャッシュの記憶領域の割当てを行うステップと、

を有することを特徴とするキャッシュの管理方法。

#### 【請求項15】

ログが記憶される論理ディスク装置がフリーのキャッシュグループに属する場合、該フリーのキャッシュグループを定義し、そのキャッシュグループにRe-Run時に必要となるログ量を割り当てるステップと有する請求項14記載のキャッシュの管理方法。

#### 【請求項16】

夫々ネットワークに接続された、データを記憶するディスク装置及び該ディスク装置に記憶されるデータの少なくとも一部を一時的に記憶するデータキャッシュを有する記憶装置と、キャッシュを有すると共に該記憶装置に対するデータ記憶の管理を行うデータベース管理システム(DBMS)プログラムが実行される計算機と、該計算機及び該記憶装置を監視、管理するためのシステム管理プログラムを備える管理用の装置とを有するデータ処理システムにおける該データキャッシュの最適な管理方法であって、

各データ構造に対して、該DBMSのキャッシュと該記憶装置のデータキャッシュの一定量をそれぞれ割り当てるステップと、

各データ構造にキャッシュ効果関数を指定し、それを用いて各データ構造に対して該DBMSのキャッシュの量を割り当てるステップと、

各データ構造にキャッシュ効果関数を指定し、それを用いて各データ構造に対してデータキャッシュの量を割り当てるステップと。

該DBMS及び又は記憶装置に対して、求めたキャッシュ量の割り当てを指示するステップと、

を有することを特徴とするキャッシュの管理方法。

**【請求項17】**

各データ構造に対して、リーフノード以外のデータを記憶するデータページの量を把握し、その量と関連させて該DBMSのキャッシュの利用量を割り当てるステップと、

各データ構造に対して、リーフノードを格納するデータページの量を基に、その量の該記憶装置におけるデータキャッシュと一定比率分のDBMSのキャッシュを割当てるステップと、

を更に有する請求項16記載のキャッシュの管理方法。

**【請求項18】**

前記データ処理システムにおいて、

前記ディスク装置を複数の論理ディスク装置として仮想化するステップと、該論理ディスク装置を単位として該データキャッシュの記憶領域のグルーピングを行うステップと、

ログが記憶される論理ディスク装置、及び該論理ディスク装置が存在するキャッシュグループをマッピング情報から求めるステップと、

求められたキャッシュグループと該グループに対応する記憶領域のキャッシュ量の設定を記憶装置に対して指示するステップと、

を有することを特徴とする請求項14又は16記載のキャッシュの管理方法。

**【請求項19】**

データ構造として表、索引データを用いることを特徴とする請求項16記載のキャッシュの管理方法。

**【請求項20】**

該DBMSは、DBMSのキャッシュと該記憶装置のデータキャッシュを1つのキャッシュと見なして管理することを特徴とする請求項16記載のキャッシュの管理方法。

**【請求項21】**

該DBMSから該記憶装置に対して該記憶装置内に格納されているデータを該データキャッシュに保持することを求めるキャッシュ化要求を発するステップと、該DBMS内のキャッシュに書き込まれたデータを該記憶装置内のデータキャッシュ

に保持することを求めるキャッシュ化要求付ライト要求を発するステップとを有することを特徴とする請求項20記載のキャッシュの管理方法。

#### 【請求項22】

夫々ネットワークに接続された、データを記憶するディスク装置及び該ディスク装置に記憶されるデータの少なくとも一部を一時的に記憶するデータキャッシュを有する記憶装置と、該記憶装置に対するデータ記憶の管理を行うデータベース管理システム(DBMS)プログラムが実行される計算機と、該計算機及び該記憶装置を監視、管理するためのシステム管理プログラムを備える管理用の装置とを有するデータ処理システムにおける該データキャッシュの最適な管理方法であつて、

DBMS内の各データ構造におけるデータページを利用待ちの発生状況を確認するステップと、

待ちが多く発生していると判断されたデータ構造を利用する処理と、そのデータ構造への期待アクセスデータページ数を把握するステップと、

データ構造を利用する処理の中で、処理時間が長く、待ちが多く発生しているデータ構造を多数回アクセスするものがないか確認するステップと、

処理時間が短くなるように、その処理が利用するデータのキャッシュヒット率を向上させるキャッシュ割当の変更を求めるステップと、

キャッシュ割当の変更に従って該記憶装置にデータキャッシュの割当の変更を指示するステップと、

を有することを特徴とするキャッシュの管理方法。

#### 【請求項23】

各処理を全体としてみたときに処理時間の総和が小さくなるように、各処理が利用するデータのキャッシュヒット率を向上させるようにキャッシュ割当の変更を求めるステップを更に有することを特徴とする請求項22記載のキャッシュの管理方法。

#### 【請求項24】

前記取得手段は、該計算機が有する前記データベース管理システム、ファイルシステム及びボリュームマネージャからのデータマッピング情報を取得すること

を特徴とする請求項1記載の装置。

### 【発明の詳細な説明】

#### 【0001】

##### 【発明の属する技術分野】

本発明は記憶装置のキャッシュ管理方法に係り、特にデータベース管理システム(DBMS)が稼動する計算機システムにおける記憶装置のキャッシュ量の設定管理に関する。

#### 【0002】

##### 【従来の技術】

サーバ計算機上で実行されるアプリケーションプログラム(APプログラム)のソフトウェア構成を調べると、データベース(DB)を基盤として利用するものが多数を占め、DBに関する一連の処理・管理を行うソフトウェアであるデータベース管理システム(DBMS)は極めて重要なものとなっている。

#### 【0003】

APプログラムの利用に際し、業務毎に定まる要求性能が存在し、それを守ることが強く求められており、それは計算機システム管理の中で極めて重要なものとなっている。DBMSの性能は、データへのアクセス性能から多大な影響を受ける。そのため、記憶装置へのアクセス性能の向上が極めて重要である。

#### 【0004】

一般的に、ディスク装置を多数保持する記憶装置においては、記憶装置内にデータを一時的に保管する高速アクセス可能なデータキャッシュを用意し、データリード時にデータがキャッシュに存在している状態(ヒット)を作り出すことによりアクセス性能を向上させる手法を用いる。米国特許第5,434,992号明細書(特許文献1)では、データ種類毎に分化されたキャッシュ領域を持つ場合に、その領域割り当てを最適化してキャッシュヒット率を向上させる技術について開示している。LRU置換アルゴリズムによるキャッシュデータ置換制御を行うシステムで、キャッシュヒット時にLRU管理リスト中のどの位置に存在するかの情報を取得し、その情報を用いて領域割り当て変更時のキャッシュヒット率の見積を行い、領域分割の最適化を行う。

### 【0005】

また、一般に、ファイルキャッシュ等の形で計算機上にもキャッシュが存在する。論文（非特許文献1）においては、計算機上のファイルキャッシュと記憶装置上のデータキャッシュを排他的に利用することにより、データへのアクセス性能を向上させる技術について論じている。この技術では、計算機上で保持されなくなったデータを記憶装置でキャッシュ化させる機構を利用する。記憶装置は、原則LRU置換アルゴリズムによりキャッシュデータ置換制御を行うが、記憶装置内のディスク装置から読み出したデータはLRU管理リスト中のLRU端に挿入し、そのデータが記憶装置のデータキャッシュに留まらないように制御する。更に、キャッシュヒット率をより一層向上させるため、ディスク装置から読み出されたデータと計算機から与えられたデータのそれぞれに関して、ゴーストLRUキャッシュと称するそれぞれ独立したLRU管理リストを用いることにより、全体を管理するLRU管理リスト中の初期挿入位置を最適化する方法についても論じている。

### 【0006】

#### 【特許文献1】

米国特許 第5,434,992号明細書

#### 【非特許文献1】

Theodore M. Wong and John Wilkes、*Whose cache is it anyway? Making storage more exclusive* USENIX Annual Technical Conference (USENIX 2002), pp. 161-175、10-15 June 2002

### 【0007】

#### 【発明が解決しようとする課題】

一般的に、DBMSにより管理されるデータは、その内容や利用目的により明確に分類される。それらは、それぞれでアクセスの特性が大きくなる。データの中には、必要とされる特性を事前に明確化することができるものもある。しかし、従来の技術では、それらの特徴を必ずしも考慮していない。

### 【0008】

特許文献1の技術では、キャッシュを分割化し、データの種類により独立した領域を割り当てるため、データ毎のアクセス特性の差を扱うことができるが、デ

ータや処理の内容までは考慮されていない。非特許文献1の技術では、データ毎のアクセス特性の差を扱うことについては特に何も考慮されていない。

#### 【0009】

本発明の目的は、DBSMが稼動する計算機システムにおいて、記憶装置のキャッシュ量を最適に設定し、性能管理コストを削減することである。

#### 【0010】

本発明の他の目的は、データの利用目的や処理内容等から生じるデータのアクセス特性の違いに基づいて記憶装置のデータキャッシュを効果的に割当てることにある。

#### 【0011】

本発明の更に他の目的は、データキャッシュのアクセスに関する稼動の統計情報に基づいて、データキャッシュの量をチューニングすることにより、キャッシュの効果を向上させることにある。

#### 【0012】

##### 【課題を解決するための手段】

本発明は、設計情報として与えられるDBMSで実行される処理に関する情報を取得し、それを基にデータ毎に利用するキャッシュ量を設定するものである。

#### 【0013】

そのために本発明は、DBMSが書き出すログに対するキャッシュ量を調整する。ログは、DBMSが異常終了した後の再起動時に処理の再実行(Re-Run)や取り消し(Undo)を実施するためにDBMSが output する情報である。それらの処理を高速に実施する必要がある場合に、その際に利用されるログは全て記憶装置のキャッシュ上に存在するようにし、ログの読み出しを高速化する。Re-Run処理時間(Undo処理時間も含む)への要求値を基に読み出されるべきログの量を把握し、その分のログは記憶装置のキャッシュ上に存在することができるようなキャッシュ量を設定する。

#### 【0014】

本発明はまた、表・索引データに対するキャッシュ量の初期割り当てを好適化する。DBMSで実施される処理の組があらかじめ明確になっている場合、処理内容

の解析からあるデータ全体へのアクセス量はおおよその見当がつく。データ内でのおおよそのアクセス特性を与え、それと処理内容の解析結果を基に、ある量のキャッシュを割り当てた場合のキャッシュヒット率の概算値を求め、データに対して割り当てるキャッシュ量を決定する。

### 【0015】

本発明はまた、稼動統計情報と組み合わせたキャッシュ量チューニングによるキャッシュ効果の向上である。事前解析により得た処理が利用するデータページ数の期待値と処理実行時の稼動統計情報を組み合わせることにより、問題と判断された処理や処理全体におけるキャッシュ量変更時の処理時間の変化を見積り、それを基に好適なキャッシュの割り当て方法を提供する。

なお、上記発明において、データ毎のアクセス特性の差を扱うため、記憶装置のキャッシュを分化し、データ毎に独立したキャッシュ領域を割り当てる。

### 【0016】

#### 【発明の実施の形態】

以下、本発明の実施の形態を説明する。なお、これにより本発明が限定されるものではない。

##### ・第一の実施の形態

第一の実施の形態は、DBMSで実施される処理の設計情報からDBMSが書き出すログに対するキャッシュ量を調整するものである。ここで、処理とはDBMSにより実施される処理である。また設計情報とは、DBMSに求められている機能や性能を実現するための情報であって、DBMSに実行させる処理の内容を規定する情報や、DBMSじ実行させる処理の実行条件を規定する情報のことと言う。例えば設計によりそれぞれの処理に対応するSQL文が作成され、複数のSQL文により1つの処理が実施されるが、これらはその処理の詳細を設計する際に見積もられる。またログは、DBMSが異常終了した後の再起動時に処理のRe-RunやUndoを実施するためにDBMSが出力する情報である。それらの処理を高速にする必要がある場合に、その際に利用されるログは全て記憶装置のキャッシュ上に存在するようにし、ログの読み出しを高速化する。Re-Run処理時間(Undo処理時間も含む)への要求値を基に読み出されるべきログの量を把握し、その分のログは記憶装置のキャッシュ上に存在

することができるようなキャッシュ量の設定を実現する。

### 【0017】

図1は、本発明の一実施形態による計算機システムの構成を示す図である。

計算機システムは、記憶装置40、記憶装置40を使用する計算機（以下「サーバ」）70、システム管理を行う計算機（以下「管理サーバ」）120、及び記憶領域の仮想化処理を行う仮想化スイッチ60を有して構成される。各々の装置はネットワークインターフェース（ネットワークI/Fと略す）22を有し、それらのI/Fを介してネットワーク24に接続され、相互に通信可能である。

### 【0018】

サーバ70、仮想化スイッチ60、及び記憶装置40は各々I/OバスI/F 32を有し、それを介して通信線（以下「I/Oバス」）34により接続される。サーバ70と記憶装置40間のI/O処理はI/Oバス34を用いて行われる。尚、I/Oバス34は、装置間で異なる物理媒体や異なるプロトコルでデータ転送を行う通信線が用いられてもよい。また、ネットワーク24とI/Oバス34が同一の通信線でもよい。

### 【0019】

記憶装置40は、CPU 12、メモリ14、ディスク装置（以下「HDD」）16、ネットワークI/F 22、I/OバスI/F 32を有し、それらは内部バス18で接続される。なお、HDD 16は例えばR A I D構成のディスク装置が好ましいが、必ずしもR A I D構成でなくても良いし、単体又は複数のH D Dでも良い。メモリ14は不揮発領域と高性能領域を有する。

### 【0020】

記憶装置40を制御するプログラムである制御プログラム44はメモリ14の不揮発領域に記憶され、起動時にメモリ14の高性能領域へ移された後にCPU 12により実行される。記憶装置40が有する機能は、全て制御プログラム44により制御されて、実現される。メモリ14には制御プログラム44が記憶装置40を制御、管理するために利用する管理情報46が記憶される。更に、メモリ14の一部は外部装置からアクセス要求のあったデータを一時的に記憶しておく領域であるデータキャッシュ42に割り当てられる。

### 【0021】

記憶装置40は、HDD 16が有する物理記憶領域を仮想化して1又は複数の論理ディスク装置（以下、「LU」と称す）208（詳細説明は図2参照）を外部装置に対して提供する。LU 208は、HDD 16と一対一に対応してもよいし、複数のHDD 16から構成される記憶領域と対応してもよい。また、1つのHDD 16が複数のLU 208に対応してもよい。その対応関係は管理情報46中に領域マッピング情報300の形で保持される。

#### 【0022】

記憶装置40では、LU 208を単位として記憶領域のグループ化が行われ、そのグループ毎に独立したデータキャッシュ42内の領域が割り当てられる。以下、このLU 208のグループを「キャッシュグループ」と称する。その構成は、管理情報46中にキャッシュグループ情報460の形で保持される。キャッシュグループの作成・削除や、それに所属するLU 208の追加・削除は動的（以下「他の処理を停止させることなく実施される」の意味で利用）に行える。また、キャッシュグループへのデータキャッシュ42の割当量を動的に変更する機能を有する。

#### 【0023】

記憶装置40は、外部からの要求に応じて、領域マッピング情報300（詳細は図3参照）やキャッシュグループ情報460（詳細は図4参照）、その他記憶装置40の構成情報を、ネットワーク24を介して外部に送信する機能を有する。また、外部装置からネットワーク24を介して外部から受信した指示に従い、前述の各種機能を実行する機能を有する。

#### 【0024】

仮想化スイッチ60は、CPU 12、メモリ14、ネットワークI/F 22、I/OバスI/F 32を有し、それらは内部バス18で接続される。メモリ14は不揮発領域と高性能領域を有する。

#### 【0025】

仮想化スイッチ60を制御するプログラムである制御プログラム64はメモリ14の不揮発領域に記憶され、起動時にメモリ14の高性能領域へ移された後にCPU 12により実行される。仮想化スイッチ60が提供する機能は、全て制御プログラム64により制御される。また、メモリ14には制御プログラム64が仮想化スイッチ60を制

御、管理するために利用する管理情報66が記憶される。

### 【0026】

仮想化スイッチ60は、本装置に接続された記憶装置40から提供されるLU 208を認識し、その記憶領域を仮想化して仮想ボリューム206を外部装置（例えばサーバ70や他の仮想化スイッチ60）に提供する。尚、仮想化スイッチ60が多段接続された場合には、他の仮想スイッチ60が提供する仮想ボリューム206を記憶装置40から提供されるLU 208と等価に扱い、その記憶領域を仮想化して仮想ボリューム206を外部装置に提供する。その対応関係は管理情報66中に領域マッピング情報300の形で保持される。仮想化スイッチ60は、外部からの要求に応じて、領域マッピング情報300やその他構成情報を、ネットワーク24を介して外部に送信する機能を有する。

サーバ70は、CPU12、メモリ14、HDD16、ネットワークI/F 22、I/OバスI/F 32を有し、それらは内部バス18で接続される。メモリ14上には、オペレーティングシステム(OS)72と管理エージェント144がHDD16から読み込まれ、CPU12により実行される。

### 【0027】

OS72は、サーバ70上で実行されるプログラムに対して、ネットワークI/F 22、I/OバスI/F 32等のハードウェア制御や、ネットワーク24を介した他の装置との通信、I/Oバス34を通してのデータ転送処理、複数プログラム間の実行制御等、基本的な処理機能を提供するプログラム群であり、ボリュームマネージャ78、ファイルシステム80を含む。メモリ14上に読み込まれたOS72は、それらや他のOS72を構成するプログラムが利用する管理情報であるOS管理情報74を有する。OS管理情報74は、サーバ70のハードウェア構成の情報を含む。OS72は、OS管理情報74中に記憶されている情報を外部プログラムが読むためのソフトウェアインターフェイスを有する。なお、本図では、サーバ70は1つのファイルシステム80しか有していないが、複数のファイルシステム80を有してもよい。

### 【0028】

ボリュームマネージャ78は、記憶装置40から提供されるLU 208や仮想化スイッチ60から提供される仮想ボリューム206の記憶領域を仮想化し、論理ボリューム2

04をファイルシステム80に提供するプログラムである。その対応関係はOS管理情報74中に領域マッピング情報300の形で保持される。また、ボリュームマネージャ78は複数I/Oバス34を利用したI/O処理の負荷分散機能を有してもよい。

#### 【0029】

ファイルシステム80は、記憶装置40から提供されるLU 208や仮想化スイッチ60から提供される仮想ボリューム206、ボリュームマネージャ78から提供される論理ボリューム204の記憶領域を仮想化し、ファイル202を他のプログラムに提供するプログラムである。その対応関係はOS管理情報74中に領域マッピング情報300の形で保持される。なお、ファイル202と同じソフトウェアインターフェイスで、論理ボリューム204、仮想ボリューム206、LU 208の記憶領域に直接アクセスする機能であるローデバイス機能も、ファイルシステム80により提供されるとする。

#### 【0030】

管理エージェント144は、管理サーバ120上で実行されるシステム管理プログラム140からネットワーク24を介して受け付けた処理要求をサーバ70で実行し、必要に応じてその結果を、ネットワーク24を介してシステム管理プログラム140に返信するプログラムである。管理エージェント144が行う処理は、(1)OS管理情報74中に記憶されている情報の読み出し、(2)DBMS管理情報92中に記憶されている情報の読み出し、等である。

#### 【0031】

DBMS90は、DBに関する一連の処理・管理を実行するサーバ70上で実行されるプログラムである。本プログラムは、HDD16もしくは記憶装置40からメモリ14に読み出されてCPU12により実行される。メモリ14上に読み込まれたDBMS90は、それが利用・管理する表・索引・ログ等（以下、まとめて「データ構造」と称する）の記憶領域の管理情報であるデータ記憶領域情報342を含む、DBMS90の管理情報であるDBMS管理情報92を有する。DBMS90は、DBMS管理情報92を外部プログラムが読むためのソフトウェアインターフェイスを有する。DBMS90は、1台のサーバ70上で複数同時に実行することができる。

#### 【0032】

OS72やDBMS90、管理エージェント144はCD-ROM（記憶媒体）に記憶されている。CD-ROMの内容は、管理サーバ120が有するCD-ROMドライブ20によって読み出され、ネットワーク24を介してサーバ70内のHDD16もしくは記憶装置40にインストールされる。

#### 【0033】

管理サーバ120は、CPU12、メモリ14、HDD16、CD-ROMドライブ20、ネットワークI/F 22を有し、それらは内部バス18で接続される。

#### 【0034】

メモリ14上には、OS72とシステム管理プログラム142がHDD16から読み込まれ、CPU12により実行される。CD-ROMドライブ20は、各種プログラムのインストールに用いられる。

#### 【0035】

管理サーバ120には、キーボード・マウス等の入力装置112および表示画面114を有する管理端末110がネットワーク24を介して接続される。この接続は、ネットワーク24とは異なる通信線を用いてもよく、管理サーバ72と管理端末110が一体で構成されてもよい。管理者は、通常管理端末110を用いて情報の入出を行なうが、必要に応じてCD-ROMドライブ20を用いることもある。

#### 【0036】

システム管理プログラム140は、管理サーバ120が有する、システム管理機能を実現するプログラムである。HDD16からメモリ14上に読み込まれ、CPU12により実行される。システム管理プログラム140は、その機能を実現するために必要な管理情報であるシステム管理情報142を有する。本プログラムはCD-ROMに記憶されており、その内容は管理サーバ120が有するCD-ROMドライブ20によって読み出され、HDD16にインストールされる。

#### 【0037】

システム管理プログラム140は、他の装置から種々の情報を取得する。このとき、記憶装置40と仮想化スイッ60が保持する情報に関しては、ネットワーク24を介して直接情報の送信要求を発行し、情報を取得する。また、サーバ70上で実行されるプログラムが保持する情報に関しては、ネットワーク24を介して管理エー

ジェント144に対して情報の読み出し要求を発行し、それが必要な情報を読み出すことにより情報を収集する。

#### 【0038】

システム管理プログラム140は、記憶装置40、仮想化スイッチ60、ボリュームマネージャ78、ファイルシステム80（以下、これらをまとめて「仮想化機構」と称する）が保持する領域マッピング情報300を、DBMS90からデータ記憶領域情報342を、記憶装置40からキャッシュグループ情報460を取得し、それらを取得元の識別子とともにマッピング集約情報としてシステム管理情報142中に記憶する。

#### 【0039】

また、システム管理プログラム140は、記憶装置40のキャッシュグループの管理において、ある特定のキャッシュグループをキャッシュ割当量の調整で優先的に削減対象とする「フリーキャッシュグループ」として扱う。特にキャッシュ量の割り当て要求がないLU208は、フリーキャッシュグループに属するとして制御する。

#### 【0040】

なお、図1では、システム管理プログラム140は管理サーバ120上で実行されているが、任意のサーバ70、仮想化スイッチ60、記憶装置40上で実行されてもよい。このとき、サーバ70ではシステム管理プログラム140はHDD16に記憶され、メモリ14に読み出された後にCPU12により実行される。仮想化スイッチ60、記憶装置40ではメモリ14の不揮発領域に記憶され、メモリ14の高性能領域に移された後にCPU12により実行される。

#### 【0041】

図2は、本実施の形態におけるDBMS90が管理するデータのデータマッピングの階層構成を示す図である。

図2を参照してサーバ70と記憶装置40との間に1つの仮想化スイッチ60が存在する場合を説明する。以下、ある2つの階層について、DBMS90に近い方を上位、HDD16に近い方を下位の階層と称する。ファイル202、論理ボリューム204、仮想ボリューム206、LU 208をまとめて「仮想構造」と称し、更に、仮想構造にHDD16を加えたものをまとめて「管理構造」と称する。

#### 【0042】

図2では、DBMS90は、それが管理しているデータ構造200を記憶しているファイルシステム80が提供するファイル202に対してアクセスを行う。ファイルシステム80は、ファイル202に対するアクセスを対応する論理ボリューム204の領域へのアクセスに変換する。ボリュームマネージャ78は、論理ボリューム204に対するアクセスを対応する仮想ボリューム206の領域へのアクセスに変換する。仮想化スイッチ60は、仮想ボリューム206に対するアクセスを対応するLU 208の領域へのアクセスに変換する。記憶装置40は、LU 208に対するアクセスを、対応するHDD16に対するアクセスに変換する。このように、仮想化機構は、それが上位階層に提供する仮想構造のデータを下位階層に存在する1つ以上の管理構造の記憶領域にマッピングする。

#### 【0043】

また、図示しないが、ある仮想構造のデータの同一部分が複数の下位階層の管理構造にマッピングされてもよい。また、ある仮想構造のデータがHDD16にマッピングされる経路が複数存在してもよい。これらの場合には、仮想化機構が、そのようなマッピングであることを領域マッピング情報300中に保持しておく。

#### 【0044】

ある管理構造が複数のサーバ70に共有されるマッピングを有してもよい。これは、フェイルオーバ構成をとるサーバ70とその上で実行されるDBMS90において利用される。

#### 【0045】

本実施の形態では、論理層212における管理構造間のデータの対応関係が明確化されればよく、サーバ70でボリュームマネージャ78が使用されなくてもよい。仮想化スイッチ60は複数段存在してもよいし、仮想化スイッチ60が存在せずにサーバ70と記憶装置40がI/Oバス34により直結されてもよい。仮想化スイッチ60に相当するスイッチが記憶領域の仮想化機能を有しなくてもよく、この場合、仮想化スイッチ60が下位階層から提供された管理構造をそのまま上位階層へ仮想構造として提供していると考える。

#### 【0046】

必須事項ではないものの、後述する記憶装置40におけるキャッシュ量の調整においては、1つのLU 208に1つのデータ構造208のみが記憶されるようにマッピングを作成すると、異なるデータを同一のキャッシュグループに混在させずに済み、その効果を高めることができる。

#### 【0047】

以下、各装置やプログラムが保持するデータ構造に関して説明する。

#### 【0048】

図3は、領域マッピング情報300のデータ構造を示す図である。領域マッピング情報300は、仮想化機構が提供する仮想構造の領域と、それが利用する管理構造の領域の対応を保持するものであり、エントリ302、304を有する。エントリ302は、仮想化機構が上位階層に提供する仮想構造の領域に関する情報であり、仮想構造の識別子である仮想構造ID 306を保持するエントリ、その構造内の領域を示すエントリ、その領域が下位階層の複数の仮想構造へ記憶されたり、異なる経路でHDD16に対応している場合に、それらを識別するための多重化方法を示すエントリの組を有する。エントリ304は、エントリ302に対応する下位階層の管理構造の領域に関する情報であり、管理構造を提供する仮想化機構の識別子である仮想化機構ID 308を保持するエントリ、管理構造の識別子である管理構造ID 310を保持するエントリ、その構造内領域を示すエントリの組を有する。なお、記憶装置40においては、仮想化機構ID 308を有するエントリを保持しない。

#### 【0049】

前述のように、異なる仮想構造が同一の管理構造の記憶領域を利用することができる。また、仮想化機構ID 308、仮想構造ID 306、管理構造ID 310はシステム内で一意に定まる識別子であるとする。そうでない場合でも、装置の識別子を付加することによりシステム内で一意に定まるようにすることができる。

#### 【0050】

図4は、キャッシュグループ情報460のデータ構造を示す図である。キャッシュグループ情報460は記憶装置40がキャッシュグループの管理に用いる情報で、キャッシュグループの識別子であるキャッシュグループID 462を保持するエントリと、そのキャッシュグループに対して割り当てるキャッシュ量の情報である

キャッシュ量466を保持するエントリ、そのキャッシュグループに属するLU 208の識別子であるLU ID 364を保持するエントリの組を有する。

#### 【0051】

図5は、データ記憶領域情報342のデータ構造を示す図である。データ記憶領域情報342は、DBMS90が管理するデータの記憶領域管理に用いる情報で、データ構造の名前であるデータ構造名346を保持するエントリ、対応するデータ構造がファイル202のどの位置に記憶されているかの情報であるデータ記憶位置348を保持するエントリの組からなる。なお、データ構造名346は、DBMS90内で一意に定まる名前であるとし、DBMS90内でDB毎に同じ名前が許される場合には、DBの識別子も含めたものを利用する。

#### 【0052】

本実施の形態においては、DBMS90は、データ構造が表である場合その属性が記憶される際の最大データサイズに関する情報である属性サイズ情報350をDBMS管理情報92中に有する。

#### 【0053】

図6は、属性サイズ情報350のデータ構造を示す図であり、表の名前であるデータ構造名346を保持するエントリ、対応する表の属性の名前である属性名352を保持するエントリ、そのエントリの記憶領域における最大サイズ354を保持するエントリの組からなる。

#### 【0054】

図7は、DBMS情報420のデータ構造を示す図である。

システム管理プログラム140は、計算機システム内で実行されるDBMS90に関する情報を、DBMS情報420としてシステム管理情報142中に保持する。この情報は、DBMS90の識別子であるDBMS ID 582を保持するエントリと、それが実行されるサーバ70の識別子であるサーバID 422を保持するエントリ、対応するDBMS90のデータ内部管理方法情報426を保持するエントリの組を含む。データ内部管理方法情報426は、DBMS90の型式により定まる、ログの出力フォーマットに関する情報を含む。

#### 【0055】

以下、本実施の形態において、ログに対して割り当てる記憶装置40におけるデータキャッシュ42の量を定める処理について説明する。この処理は、システム管理プログラム140が行う。

#### 【0056】

図8は、本処理開始時にシステム管理プログラム140に対して与えられる、処理設計情報850のデータ構造を示す図である。処理設計情報850は、処理を実施するDBMS90のDBMS ID 582を保持するエントリ、処理が実施されるDBの識別子であるDB ID 854を保持するエントリ、ログを用いて実行するRe-Run/Undo処理の処理性能に関する情報であるRe-Run性能856を保持するエントリ、Re-Run/Undo処理実施時の最大所要時間の設計情報であるRe-Run最大所要時間858を保持するエントリ、実行される処理の情報として、処理の識別子である処理ID 432を保持するエントリ、その処理が実施される比率に関する情報である実行比率862を保持するエントリ、その処理において実施されるSQL文である実行SQL文860を保持するエントリ、処理内でそのSQL文が何回実行されるかの期待値を示す期待回数864を保持するエントリの組を含む。

#### 【0057】

本実施の形態においては、Re-Run性能856は、Re-Run時に単位時間あたりに処理可能なログに記憶された処理の件数を示し、システムにおける実測値や、サーバ70の性能とDBMS90の論理的処理性能から求めた論理値、システム設計時の設定値等を与える。1つの処理で複数のSQL文が実施される可能性があり、処理ID 432に対応する実行SQL文860は複数存在しても良い。実行SQL文860が繰り返し実行される場合には、期待回数864にそれぞれ独立したものとしてカウントする。同じ処理に含まれるSQL文でも各種条件により実施されるSQL文が異なる可能性があり、実行SQL文860毎に異なる値を取り得る。なお、実行比率862や期待回数864は、設計値でもよいし、実測値でも良い。

#### 【0058】

図9は、ログのキャッシュ量を定める処理の処理フローである。前述のように、処理開始時に処理設計情報850が与えられる。また、処理により利用されるDBやその記憶領域は既に定義されているものとして説明する。ただし、対応するDB

MS90や仮想化機構から取得する情報を別途設計情報として管理者が与えることにより、それらが定義されていなくても本処理を実施できる。（ステップ1101）

処理設計情報850を参照し、Re-Run性能856とRe-Run最大所要時間858からRe-Run時に処理可能な処理の最大処理件数を求める。（ステップ1102）

処理設計情報850中の実行SQL文860を参照し、それらの中からINSERT/UPDATEを実施するSQL文と、その期待回数864を求める。（ステップ1103）

ステップ1103で求めたINSERT/UPDATEを行う実行SQL文860を1回実行した際に出力されるログの最大量を把握する。まず、対象となる実行SQL文860からデータの挿入／更新が行われる表とその属性の名前をそれぞれ把握する。そして、属性サイズ情報350を参照してそれらの最大サイズ354を求める。また、DBMS情報420中のデータ内部管理方法情報426からログの出力フォーマットの情報を取得し、それらから各実行SQL文860においてログとして出力される最大データ量を把握する。（ステップ1104）

ステップ1103とステップ1104で求めた値を用いて、ログを出力する各処理の1件あたりのログ出力量を計算する。この値は、ある処理に属するINSERT/UPDATEを行う実行SQL文860によるログの最大データ量と期待回数864の積の値の和として求める。更に、DBMS情報420中のデータ内部管理方法情報426からログのヘッダや処理がコミットされたときに出力されるデータ等の出力フォーマットに関する情報を把握し、その分もログ出力量に加える。最後に、求めた値を、記憶装置のブロックサイズ（512byte）を単位として切り上げ処理を実施する。（ステップ1105）

ステップ1105で求めたログを出力する処理1件あたりのログ出力量と、処理設計情報850中の各処理における実行比率862から、ログを出力する処理1件あたりの平均ログ出力量を求める。そして、この値とステップ1102で求めたRe-Run時に処理可能な最大処理件数の積の値に、事前に定めた余裕分を加えた量をRe-Run時に必要となるログ量とする。（ステップ1106）

ステップ1106で求めた量のログが記憶装置40上に常に存在するようなキャッシュ量の設定を求める。DBMS90のログがどの記憶装置40に記憶され、更に、そのログがどのLU208上に記憶され、そのLU208がどのキャッシュグループに存在するか

、マッピング集約情報から把握する。求めたキャッシュグループに対し、ステップ1105で求めたRe-Run時に必要となるログ量以上のキャッシュを割り当てる。なお、記憶装置40が書き込まれたデータを2重化する場合には、必要に応じてログ量に対して2倍のキャッシュ量が必要であるとする。

#### 【0059】

ログが記憶されるLU208がフリーキャッシュグループに属する場合には、それらのみのキャッシュグループを定義し、そこにRe-Run時に必要となるログ量を割り当てる事とする。複数のLU208に分割されてログが記憶され、かつ、それらが異なるキャッシュグループに属する場合には、それぞれにRe-Run時に必要となるログ量を割り当てる。ログが記憶されるLU208が属するキャッシュグループに他のデータも記憶されるマッピングがマッピング集約情報から得られた場合、例えば、以前のキャッシュグループの設定値から他のデータが記憶される分のキャッシュ量を別途求め、その値にRe-Run時に必要となるログ量を加算した値をそのキャッシュグループのキャッシュ量とする。（ステップ1107）

ステップ1106で求めたキャッシュグループとそのキャッシュ量の設定を、記憶装置40に対して発行する。処理に利用されるDBがDBMS90でまだ定義されていない場合には、その定義と記憶領域を確保した後にこのステップを実施する。（ステップ1108）

そして、処理を完了する。（ステップ1109）

これまで、記憶装置40はLU208を外部装置に提供し、それはI/Oバス34を経由してアクセスされるとしてきた。記憶装置40がファイル202を外部装置に提供し、そのファイル202がネットワークファイルシステムプロトコルを用いてネットワーク24経由でアクセスされてもよい。

#### 【0060】

図10は、上述した第一の実施形態の変形例であり、記憶装置40がファイル202を外部装置に提供する場合の計算機システムの構成を示す図である。その場合には、以下のような違いがある。

#### 【0061】

サーバ70はI/OバスI/F 32を有さなくともよい。OS72は外部装置が提供するフ

ファイル202を、ネットワークファイルシステムプロトコルを用いてネットワークI/F 22、ネットワーク24経由でアクセスするネットワークファイルシステム82を含み、ボリュームマネージャ78やファイルシステム80を有さなくともよい。ネットワークファイルシステムは領域マッピング情報300をOS管理情報74中に有する。DBMS90により認識されるファイル202と記憶装置40から提供されるファイル202があるルールに従って対応する場合、その対応関係を定めるルールの情報のみがOS管理情報74中に保持されても良い。この場合には、システム管理プログラム140は対応関係を定める情報を取得し、それから領域マッピング情報300を作成し、マッピング集約情報中に記憶する。

#### 【0062】

記憶装置40はI/OバスI/F 32を持たなくてもよく、ファイルを外部装置に対して提供する。記憶装置40の制御プログラム44はファイルシステム80が提供する機能を有し、記憶装置40内に存在するLU208の記憶領域を仮想化し、ファイル202を提供する。また、制御プログラム44は1つ以上のネットワークファイルシステムプロトコルを解釈し、ネットワーク24、ネットワークI/F 22経由で外部装置からそのプロトコルを用いて要求されるファイルアクセス処理を実施する。この記憶装置40では、キャッシュグループのメンバの管理単位がLU208ではなくファイル202を単位とする。

#### 【0063】

データのマッピングに関しては、図2で説明したデータのマッピング階層構成において、ファイル202以下が全て記憶装置40により提供されるようになり、サーバ70はOS72内のネットワークファイルシステム82を用いて記憶装置40上にあるファイル202をアクセスする。

記憶装置40がファイル202を外部装置に提供する場合、本実施の形態において実施する処理においては、LU208を考えている部分を記憶装置40上のファイル202に対応させる。

#### 【0064】

##### ・第二の実施の形態

第二の実施の形態では、DBMSで実施される処理の設計情報から表・索引データ

に対するキャッシュ量の初期割り当てを好適化する。DBMSで実施される処理の組があらかじめ明確になっている場合、処理内容の解析からあるデータ全体へのアクセス量はおおよその見当がつく。データ内でのおおよそのアクセス特性を与え、それと処理内容の解析結果を基に、ある量のキャッシュを割り当てた場合のキャッシュヒット率の概算値を求め、データに対して割り当てるキャッシュ量を決定する。本実施の形態では、計算機システムが、DBMSのキャッシュと記憶装置のデータキャッシュを1つのキャッシュ領域とみなして管理するための機構を有し、双方で記憶データの重複がほとんどないことを前提とする。

#### 【0065】

図11は、第二の実施形態による計算機システムの構成を示す図である。第二の形態における計算機システムの構成は、第一の形態のものと基本的に同じである。以下、第一の形態との差異を中心にして第二の実施形態について説明する。

#### 【0066】

DBMS90は、メモリ14上上の領域をキャッシュ94として利用し、DBMS管理情報92中に表データ量情報700とB-Tree索引情報710を含むDBMS90bとなる。DBMS90bは属性サイズ情報350を保持する必要はない。DBMS90bは、データ構造毎にキャッシュ94の利用量を管理する機能を有し、その設定情報は表データ量情報700やB-Tree索引情報710に含まれる。DBMS90bは、データ構造毎のキャッシュ94の利用量を動的に変更するためのソフトウェアインターフェイスを有する。

#### 【0067】

管理エージェント144がシステム管理プログラム140からの指示に従って実行する処理に、データ構造毎のキャッシュ94の利用量の変更をDBMS90bに指示することが加わる。システム管理プログラム140は、システム管理情報142中に保持するDBMS情報420にデータ内部管理方法情報426を有する必要はない。

#### 【0068】

更に大きな違いとして、I/Oバス34を通してキャッシュ化要求954とキャッシュ化要求付ライト要求958が伝達される。キャッシュ化要求954は、記憶装置40b内に格納されているデータをデータキャッシュ42に保持することを求める要求であり、通常のリード要求950と同様の形式でデータが指定される。キャッシュ化要

求付ライト要求958は書き込まれたデータを記憶装置40b内でデータキャッシュ42に保持することを求める要求である。

#### 【0069】

キャッシュ化要求954とキャッシュ化要求付ライト要求958を使用した例として、I/Oバス34上でのデータ転送プロトコルとしてSCSI(Small Computer System Interface)を基にしたものを利用する場合について説明する。第一の方法としては、キャッシュ化要求954とキャッシュ化要求付ライト要求958に対応するオペレーションコードを新規に作成する。第二の方法としては、既存のプリフェッチとライトのオペレーションコードを利用し、コマンド中のコントロールバイトのベンダ依存ビットにキャッシュヒントを意味するビットを定義し、その値が“0”的時には通常の処理を、その値が“1”的ときに、オペレーションコードがプリフェッヂコマンドの場合にはキャッシュ化要求954、オペレーションコードがライトのときにはキャッシュ化要求付ライト要求958として処理する。なお、他のデータ転送プロトコルを用いても同様の方法で実現可能である。

#### 【0070】

本実施の形態においては、仮想化スイッチ60は、仮想ボリューム206へのキャッシュ化要求954とキャッシュ化要求付ライト要求958を、対応する管理構造へのキャッシュ化要求954やキャッシュ化要求付ライト要求958に変換する機能を制御プログラム64により実現する仮想スイッチ60bとなる。サーバ70上のOS72は、上位プログラムからのキャッシュ化要求954とキャッシュ化要求付ライト要求958をI/Oバス34を通して送出可能なOS72bに変更される。DBMS90bはキャッシュ化要求954とキャッシュ化要求付ライト要求958を送出する機能を有する。記憶装置40は、制御プログラム44によりキャッシュ化要求954とキャッシュ化要求付ライト要求958が解釈可能な記憶装置40bとなる。

#### 【0071】

本実施の形態において、記憶装置40のキャッシュグループ情報460は記憶装置40bではキャッシュグループ情報460bとなる。キャッシュグループ情報460b中のヒント機能468の値が“ON”であるキャッシュグループに属するLU208内のデータに対してキャッシュ化要求954やキャッシュ化要求付ライト要求958を受け取った場

合、それらにより指示されたデータに関しては長時間データキャッシュ42に保持するようにする。例えば、記憶装置40bがキャッシュグループ内のデータ領域の管理を、LRU置換アルゴリズムを用いて行う場合、要求データをMRUデータ化する。なお、キャッシュ化要求954を受け取り、それで指示されたデータがデータキャッシュ42内に存在しない場合、そのデータをHDD16から読み出してデータキャッシュ42上に格納する。そのLU208に対してリード要求950やライト要求956があった場合、その要求を完了後、そのデータは原則データキャッシュ42には保持しない。記憶装置40bの内部制御の都合上、データキャッシュ42に保持する必要がある場合でも、保持する必要がなくなったら、そのデータを保持する領域がすぐに再利用されるようにする。（前述の例ではその時点のLRUデータとして扱う。）

図12は、キャッシュ化要求954とキャッシュ化要求付ライト要求958を用いた際の、DBMS90bと記憶装置40bとの間のデータ制御を説明した図である。各領域での処理開始時にDBMS90bや記憶装置40bはそのデータをキャッシュ94やデータキャッシュ42上に保持していない。なお、図を簡略化するため、処理の受諾や完了の応答は図から省いてある。

### 【0072】

領域962は、DBMS90bがデータの読み出しのみを行った際のデータ制御を示す。まず、DBMS90bがリード要求950を記憶装置40bに発行し、それに応答して記憶装置40bがDBMS90bに要求されたデータを転送する（データ転送952）。記憶装置40bはデータを転送した後、そのデータをデータキャッシュ42に保持しない。DBMS90bは転送されたデータをキャッシュ94に格納する。DBMS90bは、データをキャッシュ94から破棄する際に、リード要求950と同様の方法でキャッシュ化要求954を記憶装置40bに送出する。キャッシュ化要求954を受け取った記憶装置40bは要求データをHDD16から読み出し、データキャッシュ42上に保持する。

### 【0073】

領域964は、DBMS90bがデータの更新を行う際の第一のデータ制御を示す。DBMS90bがデータをキャッシュ94上に読み出すまでは領域962と同様である。その後、DBMS90bはキャッシュ94上のデータを更新し、更新したデータを記憶装置40bに書

き込む（ライト要求956+データ転送952）。記憶装置40bは、受領したデータを対応するHDD16に書き込み、データキャッシュ42上にそのデータを保持しない。その後、DBMS90bは、データをキャッシュ94から破棄する際に、キャッシュ化要求954を記憶装置40bに送出する。キャッシュ化要求954を受け取った記憶装置40bは要求データをHDD16から読み出し、データキャッシュ42上に保持する。

#### 【0074】

領域966は、DBMS90bがデータの更新を行う際の第二のデータ制御を示す。DBMS90bがデータをキャッシュ94上で更新するまでは領域964と同様である。データ更新後、本制御では、キャッシュ94上からデータを破棄するまで記憶装置40bへのデータ書き込みを行わない。データをキャッシュ94から破棄する際に、DBMS90bは、更新したデータを記憶装置40bに書き込むと同時にキャッシュ化要求を行う（キャッシュ化要求付ライト要求958+データ転送952）。キャッシュ化要求付ライト要求958を受け取った記憶装置40bは書き込まれたデータをデータキャッシュ42上に保持する。データのHDD16への書き込みは適宜行う。

#### 【0075】

なお、これまでの説明はキャッシュ化要求954を用いた方法で説明してきたが、DBMS90bがデータ破棄時に常にキャッシュ化要求付ライト要求958を発行しても良い。この場合、各装置はキャッシュ化要求954を処理できる必要はない。

#### 【0076】

図13は、キャッシュグループ情報460bのデータ構造を示す図である。第一の実施の形態と比較して、キャッシュグループID 462を保持するエントリ毎にヒント機能468を保持するエントリが付加される。ヒント機能468はキャッシュヒント機能が有効か無効かを示す情報で、有効な場合は“ON”が、無効な場合には“OFF”がその値として記憶される。ヒント機能468の値が“ON”的きの制御は前述の通りである。その値が“OFF”的場合は、一般的なキャッシュのデータ管理办法を用いる。例えば、データキャッシュ42内に保持されるデータをLRU置換アルゴリズムで管理し、アクセスされたデータはその種別に関わらず全てその時点でMRUデータ化する。

#### 【0077】

図14は、表データ量情報700のデータ構造を示す図である。表データ量情報700は、表のデータ構造名346を保持するエントリと、その表におけるデータページの大きさに関する情報であるデータページサイズ702を保持するエントリとその表が利用しているデータページ数704を保持するエントリ、そのデータが利用可能なキャッシュ94の量に関する情報であるキャッシュ量466を保持するエントリを有する。

### 【0078】

図15は、B-Tree索引情報710のデータ構造を示す図である。B-Tree索引情報710は、索引のデータ構造名346を保持するエントリと、その索引が付加された表のデータ構造名346である対応表名712を保持するエントリ、データページサイズ702を保持するエントリ、データページ数704を保持するエントリ、データページのうち、B-Tree索引のリーフノードのデータを保持しているデータページ数であるLeafノードページ数714を保持するエントリ、その索引のキャッシュ量466を保持するエントリ、その索引を利用して検索が行われる属性の属性名352の組である検索属性716を保持するエントリ、検索属性716における1回の検索で得られると期待されるタプル数の情報である期待タプル数718を保持するエントリの組からなる。なお、1つの索引に複数の検索属性716とそれに対応する期待タプル数718が存在することがある。また、期待タプル数718は、対応する表のデータ解析により得られる値で、平均値や最頻値、あるいは各種指標から計算した値が用いられる。

### 【0079】

以下、本実施の形態において、DBMS90bや記憶装置40bにおけるキャッシュ量を設定する処理を説明する。本処理は、システム管理プログラム140が行う。

### 【0080】

図16は、キャッシュ量情報720のデータ構造を示す図である。キャッシュ量情報720は、処理開始時にシステム管理プログラム140に対して与えられる、DBMS90bや記憶装置40bにおいて利用可能なキャッシュ量に関する情報であり、処理が実施されるDBMS90bのDBMS ID 582を保持するエントリとそのDBMS90bで利用可能なキャッシュ94の量に関する情報であるキャッシュ量722を保持するエントリの組

と、処理に利用されるデータを保持する記憶装置40b（装置）の識別子である装置ID 572を保持するエントリとそこで利用可能なデータキャッシュ42の量であるキャッシュ量722を保持するエントリの組を含む。

### 【0081】

図17は、処理開始時にシステム管理プログラム140に対して与えられる情報である、表アクセス分布情報730のデータ構造を示す図である。表アクセス分布情報730には、処理に利用される表のデータ構造名346を保持するエントリと、その表におけるデータページへのアクセス頻度の分布に関する情報であるアクセス分布732を保持するエントリの組を含む。アクセス分布732は、アクセス頻度が高い順に並び替えられているとし、理論値／実測値のどちらでもよい。その分布がわからない場合には一般化されたZipf分布に従うとし、k番目に高いアクセス確率を持つデータページへのアクセス確率をF(k)としたときに、 $F(k) = C/k^\alpha$  ( $\alpha$ ：パラメータ ( $0 <= \alpha$ )、C：補正係数 ( $C=1/\sum(1/c^\alpha)$ )) である仮定する。このとき、データページ数が少ない場合には $\alpha$ を0に近い値（例えば0.25程度）とし、データページ数が多い場合には $\alpha$ を1に近い値（例えば0.75程度）とする。また、データのINSERTが行われる、INSERTされたデータがある程度の時間経過後に更新される、等の時間的局所性を有する処理が行われる場合には、それによりアクセスされる領域が限られ、データページの一定割合（例えば8割）はデータアクセスがされない（アクセス確率が0）としてもよい。

### 【0082】

図18は、システム管理プログラム140がシステム管理情報142中に保持する期待アクセスページ数情報780のデータ構造を示す図である。期待アクセスページ数情報780は、処理ID 432を保持するエントリ、その処理によりアクセスされるデータ構造のデータ構造名346を保持するエントリと、そのデータ構造に対して処理あたり幾つの異なるデータページが利用されると期待されるかの情報を示す期待アクセスデータページ数784を保持するエントリの組からなる。期待アクセスデータページ数784は、参照と更新（データの挿入を含む）の双方を含めてアクセスされるデータページ数の総計値を保持するエントリと、更新が行われる（参照のみを除いた）データページ数が保持されるエントリを有する。

### 【0083】

期待アクセスページ数情報780は設計情報として管理者が与えてもよいし、また、キャッシュ量を設定する処理を開始する前に、システム管理プログラム140に処理設計情報850を与える、それから以下のように作成してもよい。なお、この場合の処理設計情報850には、Re-Run性能856とRe-Run最大所要時間858を保持するエントリが含まれなくともよい。

### 【0084】

まず、処理設計情報850から実行SQL文860を参照し、それぞれのSQL実行計画をDBMS90bから取得、各処理ステップでアクセスされるデータ構造とそのアクセス方法（データの挿入／更新を含む）を把握する。その結果と、DBMS90bから取得するB-Tree索引情報710を利用し、SQL実行計画中の各処理ステップにおいて処理するデータ量（タプル数）を把握する。求めたアクセスされるデータ構造と、そのアクセス方法と、各処理ステップにおける処理データ量から、アクセスされるデータページ数とアクセス内容（参照／更新）を把握する。このとき、基本的に、各タプルは異なるデータページに存在すると考える。ただし、あるB-Tree索引により検索されるタプルがどのようにデータページに分散されるかの情報をB-Tree索引情報710中に含めておき、それをを利用してアクセスされるデータページ数をより詳細に求めるてもよい。この処理の全部／一部として、DBMS90bでSQL実行計画を作成するときに内部的に見積られた値をSQL実行計画と同時に出力させ、その値を利用してよい。求めた値に、実行SQL文860に対応する期待回数864を乗じた値を期待アクセスページ数情報780に設定する。

### 【0085】

図19は、DBMS90bや記憶装置40bにおけるキャッシュ量を設定する処理の処理フローである。本処理においては、各データ構造毎に、DBMS90bと各記憶装置40bにおけるキャッシュ量の割り当てを求めるものとする。処理開始前に期待アクセスページ数情報780がシステム管理情報142中に保持される。処理開始時、処理設計情報850b、キャッシュ量情報720、表アクセス分布情報730が与えられる。なお、処理設計情報850bは、処理設計850から実行SQL文860と期待回数864を保持するエントリが除かれたものである。ここでは、処理により利用されるDBやその記憶領

域は既に定義されているものとして説明する。ただし、対応するDBMS90bや仮想化機構から取得する情報を別途設計情報として管理者が与えることにより、それらが定義されていなくても本処理を実施できる。（ステップ1401）

まず、表・索引の各データ構造に対して、処理を実施する際に必要となる最小限の量として、DBMS90bにおけるキャッシュ94と各記憶装置40bにおけるデータキャッシュ42での利用量を、それぞれ事前に定められる一定量分割り当てる。

### 【0086】

なお、本処理の全てのステップにおいて、データの記憶先の記憶装置40bは、システム管理情報142中に保持されているマッピング集約情報から把握する。複数の記憶装置40bに対してデータが記憶されている場合には、特に断らない限り、マッピング集約情報から各記憶装置40b毎のデータの記憶比率を把握し、それに比例したキャッシュ量をそれぞれに割り当てる。DBMS90bや記憶装置40bにおいて、キャッシュ量情報720中にキャッシュ量722として与えられたキャッシュの利用量の上限を超えた量を要求する場合にはエラーとして処理を終了する。（ステップ1402）

次に、DBMS90bからB-Tree索引情報710を取得する。その後、各索引毎に、取得した情報中のデータページ数704とLeafノードページ数714の差とデータページサイズ702から、リーフノード以外のデータを記憶するデータページの量を把握し、それと同量のキャッシュ94の利用量を割り当てる。（ステップ1403）

続いて、各索引毎に、Leafノードページ数714とデータページサイズ702からリーフノードのデータ量を把握し、それと同量のデータキャッシュ42の利用量と、それに対して事前に定められた比率（例えば20%）分のキャッシュ94の利用量を割り当てる。（ステップ1404）

各表毎にキャッシュ効果関数を指定し、ステップ1601から始まる処理を実施し、各表のデータに対してキャッシュ94の利用量を指定する。ここで、キャッシュ効果関数E(i)は「あるデータ構造における、データを利用するときに既にそのデータがキャッシュ上に存在する（キャッシュヒットする）確率の、キャッシュ上に保持可能なデータページ数をi-1からiに増加させたときの増分」と定義する。従って、 $\sum E(i)=1$ である。ここでは、近似として表アクセス分布情報730で与え

られるアクセス分布732をそのまま与える。ただし、アクセス分布732をベースにキャッシュ効果関数を別途定義してもよい。（ステップ1405）

記憶装置40bにおいて、データキャッシュ42がライトキャッシュとしても利用される場合に、各データ構造にその利用分を考慮したデータキャッシュ42を割り当てる。まず、処理設計情報850b中の期待アクセスページ数情報720を参照し、期待アクセスデータページ数784の更新データページ数の値が0でないデータ構造を有する処理を求める。それらの処理のうちどれか1つが実施された際の各データ構造毎の期待データページ更新数を、処理設計情報850b中の処理の実行比率862による重み付けを考慮しながら期待アクセスデータページ数784の更新データページ数から求める。次に、処理設計情報850b中のRe-Run性能856とRe-Run最大所要時間858からRe-Run時に処理可能な処理の最大処理件数を求め、それと既に求めた更新が行われる処理あたりの各データ構造毎の期待データページ更新数の積を求める。

#### 【0087】

求めた値と、データ構造における現在のキャッシュ94の割り当て量に事前に定めた割合（例えば70%）を乗じた値を比較し、そのうち値が小さな方をデータ構造に対するライトキャッシュ必要量とする。データキャッシュ42の割当量がその値未満のデータ構造に対して、その量に達するようにデータキャッシュ42の割り当てを行う。なお、ある記憶装置40bが書き込まれたデータを2重化する場合には、必要に応じて求めた値の2倍のキャッシュ量が必要であるとする。

#### 【0088】

なお、本ステップは必ずしも実施される必要はない。この場合、処理設計情報850b中にRe-Run性能856やRe-Run最大所要時間858が保持される必要はない。（ステップ1406）

各表毎にキャッシュ効果関数を指定し、ステップ1601から始まる処理を実施し、各表のデータに対してデータキャッシュ42を割り当てる。ここでも、キャッシュ効果関数は、近似として表アクセス分布情報730で与えられるアクセス分布732をそのまま与える。ただし、アクセス分布732をベースにキャッシュ効果関数を別途に定義してもよい。特に、DBMS90bでのキャッシュ94の制御方法、記憶装置4

0bにおけるデータキャッシュ42の制御方法の違いを考慮して、ステップ1405と異なる関数を用いててもよい。（ステップ1407）

これまでに求めたキャッシュ量の設定を、DBMS90bや記憶装置40bに対して発行する。処理に利用されるDBがDBMS90bでまだ定義されていない場合には、その定義と記憶領域の確保と同時、もしくは確保後にこのステップを実施する。

#### 【0089】

記憶装置40bへのキャッシュ量の指示は以下のように行う。マッピング集約情報参照し、処理で利用されるデータ構造のデータを保持するLU208を確認し、それがフリーキャッシュグループに属している場合には、同じデータ構造のデータが記憶されるLU208をメンバとするキャッシュグループを作成するように記憶装置90bに対して指示を出す。その後に各データ構造を記憶するLU208が属するキャッシュグループに対して求めたキャッシュ量の設定を行う。なお、あるデータ構造のデータが異なるキャッシュグループに属する複数のLU208上に記憶される場合には、マッピング集約情報からそれぞれに記憶されているデータ量を把握し、それに比例するように割当を行う。マッピング集約情報から、データ構造のデータが他のデータと同一のキャッシュグループに属することになる場合には、それらのデータ構造に対して割りあてられた量の和としてキャッシュグループのキャッシュ量を設定する。このとき、本処理によるキャッシュ量の割当とは別に割り当てが行われている場合には、必要に応じて、以前のキャッシュグループの設定値から他のデータが記憶される分のキャッシュ量を別途求める。（ステップ1408）

そして、処理を完了する。（ステップ1409）

なお、本処理は、記憶装置40bのデータキャッシュ42の割当のみを実施する場合に実行しても良い。この場合、DBMS90bにおける各データ構造へのキャッシュ94の割当が処理開始時に与えられる。そして、ステップ1402からステップ1405までと、ステップ1408におけるキャッシュ94に関する処理は実施しない。

#### 【0090】

図20は、キャッシュ効果関数を利用してキャッシュ量の割り当てを行う処理の処理フローを示す。本処理はステップ1401から始まる処理の一部であり、その処

理が利用可能な情報は全て利用できる。以下、説明のため、処理に利用される表に通番tを付加し、各表毎に定まる定数や関数等は、この通番を利用してそれのものとして識別する。本処理の開始時、各表毎にキャッシュ効果関数E<sub>t</sub>(i)と割り当てを行うキャッシュがDBMS90bのキャッシュ94か記憶装置40bのデータキャッシュ42かに関する指定が与えられる。また、必要に応じて、現在のキャッシュ割当量を求める方法も指定される。（ステップ1601）

現在までに割り当てられたキャッシュ量を各表毎に求め、それをデータページ数に換算した値をn<sub>t</sub>に設定する。このとき、処理開始時に特に指定がない限り、キャッシュ94とデータキャッシュ42のそれぞれに割り当てられた値の総計としてキャッシュ量を求める。（ステップ1602）

次に、各表毎に以下の値を計算する。

#### 【0091】

$$A_t = \Sigma ((\text{表に対する処理の期待アクセスページ数 (総計値)}) \times (\text{処理の実行比率}))$$

ここで、Σは処理に関して総和を取ることを示す。表に対する処理の期待アクセスページ数は期待アクセスページ数情報780から求めることができ、処理の実行比率は処理設計情報850bから求めることができる。（ステップ1603）

次に、各表毎に指定されたキャッシュ効果関数を用いて以下の値を計算する。

#### 【0092】

$$W_t(n_t) = A_t \times E_t(n_t)$$

（ステップ1604）

ステップ1604で求めたW<sub>t</sub>(n<sub>t</sub>)の値が一番大きな表を選択し、その表に対して1データページ分キャッシュを割り当てる。

#### 【0093】

データキャッシュ42の割り当ての場合には、W<sub>t</sub>(n<sub>t</sub>)の選択後に以下の処理も行う。マッピング集約情報を参照して、その表のデータがどの記憶装置40bにどれだけの量が記憶されているかを求め、その量に比例して追加されたデータキャッシュ42の割り当て量を記憶装置40b間で分配する。このとき、特定の記憶装置40bにおける、各データ構造に対するデータキャッシュ42の割当量の和がキャッシュ

量情報720中にキャッシュ量722として与えられた値に達している場合には、そこへの割り当ては不可能とし、他の記憶装置40bのみを考えて追加されたキャッシュ量の分配を行う。選択された表において、そのデータを保持する全ての記憶装置40bでデータキャッシュ42の割り当てが不可能と判断される場合、その表に対するキャッシュの割り当ては行わず、次に $W_t(n_t)$ の値が大きな表をキャッシュの割り当て対象とし、同様の確認を繰り返す。

#### 【0094】

そして、選択された表の $n_t$ の値に1を加える。（ステップ1605）

キャッシュが全て割り当てられたか確認し、まだ割り当て可能な未割り当て分が存在する場合にはステップ1604に戻る。割り当てが完了した（これ以上割り当てる続行できない）場合には、ステップ1607に進み、処理を完了する。（ステップ1606）

ここで、処理を完了する。（ステップ1607）

これまで、記憶装置40bはLU208を外部装置に提供し、それはI/Oバス34を経由してアクセスされるとしてきた。第一の実施の形態と同様に、記憶装置40bがファイル202を外部装置に提供し、そのファイル202がネットワークファイルシステムプロトコルを用いてネットワーク24経由でアクセスされてもよい。この場合、第一の実施の形態と同様の対応関係がとられる。

#### 【0095】

主な相違点として、記憶装置40bでは、キャッシュグループのメンバの管理単位が、ファイル202が単位となり、本実施の形態において実施する処理においては、LU208の部分が記憶装置40b上のファイル202に対応するようになる。

##### ・第三の実施の形態

第三の実施の形態は、第二の実施の形態において利用されていたキャッシュ化要求954とキャッシュ化要求付ライト要求958が利用されない条件の下、DBMSで実施される処理の設計情報から表・索引データに対するキャッシュ量の初期割り当てを好適化する。つまり、本実施の形態では、DBMSのキャッシュと記憶装置のデータキャッシュがそれぞれ独立に管理され、双方の間でキャッシュ上に保持されるデータが一部重複することを前提とする点が第二の実施の形態と異なる。

### 【0096】

第三の実施における計算機システムの構成は、基本的に第二の実施形態のものと似ている。以下、本実施の形態について第二の実施形態との違いを中心にして説明する。

### 【0097】

前述のように、本実施の形態においては、キャッシュ化要求954とキャッシュ化要求付ライト要求958が利用されない。そのため、記憶装置40b、仮想化スイッチ60b、OS72bは、第一の実施の形態と同じ記憶装置40、仮想化スイッチ60、OS72となる。また、DBMS90bは、キャッシュ化要求954とキャッシュ化要求付ライト要求958を送出する機能を有さないDBMS90cになる。

### 【0098】

記憶装置40では、データキャッシュ42内のデータ管理に関し、一般的な手法を用いる。例えば、データキャッシュ42内に保持されるデータをLRU置換アルゴリズムで管理し、アクセスされたデータはその種別に関わらず全てその時点でMRUデータ化する。

### 【0099】

本実施の形態では、ステップ1401から始まるキャッシュ量を設定する処理がステップ1401bから始まる処理に変更される。図21は、ステップ1401bから始まるDBMS90cや記憶装置40におけるキャッシュ量を設定する処理の処理フローである。ステップ1401bから始まる処理では、ステップ1401から始まる場合に実行されるステップ1407がステップ1421からステップ1423までの処理に変更される。なお、本処理は、第二の実施の形態と同様にして、記憶装置40のデータキャッシュ42の割当のみを実施する場合に実行しても良い。

### 【0100】

表のデータ量を表データ量情報700から求め、その値の一定割合（例えば90%）以上の量のキャッシュ94が割り当てられた表を、以降の記憶装置40のデータキャッシュ42の割り当て対象から除く選択処理を行う。（ステップ1421）

次に、ステップ1407と同様に、各表毎にキャッシュ効果関数を指定し、ステップ1601から始まる処理を実施し、各表のデータに対してデータキャッシュ42の利

用量を割り当てる。このとき、ステップ1602で設定する現在までに割り当てられたキャッシュ量は、記憶装置90におけるデータキャッシュ42の割当量のみを考慮するように指示する。キャッシュ効果関数は、キャッシュ94とデータキャッシュ42の間でのデータの重複を考慮しないものを与えるとし、近似として表アクセス分布情報730で与えられるアクセス分布732をそのまま与える。また、別途キャッシュ効果関数を定義してもよい。なお、本ステップで割り当てたデータキャッシュ42の量は、全体の割当量とは別に記憶する。（ステップ1422）

ステップ1422で割り当てたデータキャッシュ42に関し、キャッシュ94とデータキャッシュ42の間でのデータ重複によるデータキャッシュ42のキャッシュ効果低減分を考慮する、データキャッシュ42の割り当ての再調整を行う。本実施の形態では、現在のキャッシュ94の利用量に一定割合（例えば80%）を乗じた値（以下、 $N_t$ と表記）未満の領域では、データキャッシュ42を利用してもその効果がないと判断する。まず、ステップ1422でデータキャッシュ42が割り当てられなかった表を再調整の対象から外す。

#### 【0101】

次に、ステップ1422でデータキャッシュ42が割り当てられてたものに対してキャッシュ効果があるか確認する。調整対象の各表において、 $n_t$ を現時点でのデータキャッシュ42の割当量から求めたデータページ数としたとき、確認指標として $n_t - N_t < 0$ を用い、それ満たす表が存在する場合には、その値が最も小さな表のステップ1422以降で割り当てたデータキャッシュ42を全て開放し、調整対象から外す。そして、ステップ1422で行ったデータキャッシュ42の割当処理を再度実行する。以下、確認指標を満たす表が存在する間この確認と再割当処理を繰り返す。この確認で、全ての表でステップ1422で割り当てたデータキャッシュ42を開放することになった場合は、エラー発生として処理を終了する。なお、確認指標にキャッシュ効果より強く反映させるために、 $n_t - N_t < 0$ の代わりに $(n_t - N_t) / W_t(N_t) < 0$  ( $W_t(i)$ はステップ1604での定義を利用) を用いてもよいし、他の確認指標を用いてもよい。

#### 【0102】

更に、キャッシュ効果を高めるため、調整対象の全ての表で $n_t - N_t > 0$ を満たす

場合に、キャッシュ効果を考慮した割当の調整を行う。調整対象の各表において  $V_t = \sum W_t(i)$  (ただし  $\Sigma$  は  $N_t \leq i \leq n_t$  の和を取ることを意味する) を計算し、その値が最も小さな表を選択する。その表に対してステップ1422以降で割り当てられたデータキャッシュ42を開放した場合に、他の調整対象の表に割り当てる方法をステップ1422と同様にして求める。ここで、新規割当先に対応する  $W_t(i)$  の値の和を計算し、その値がデータキャッシュ42を開放した表における  $V_t$  よりも大きな値の場合、求めたキャッシュ割当の再調整を実施するとする。以下、この確認を再調整を実施しないと判断されるまで繰り返す。（ステップ1423）

これまで、記憶装置40はLU208を外部装置に提供し、それはI/Oバス34を経由してアクセスされるとしてきた。第一の実施の形態と同様に、記憶装置40がファイル202を外部装置に提供し、そのファイル202がネットワークファイルシステムプロトコルを用いてネットワーク24経由でアクセスされてもよい。この場合、第一の実施の形態と同様の対応関係がとられる。

### 【0103】

主な相違点として、記憶装置40では、キャッシュグループのメンバの管理単位がファイル202単位となり、本実施の形態において実施する処理においては、LU208の部分が記憶装置40上のファイル202に対応するようになる。

#### ・第四の実施の形態

第四の実施の形態では、DBMSで実施される処理の設計情報と稼動統計情報と組み合わせ、記憶装置におけるデータキャッシュ量のチューニングによりキャッシュ効果を向上させる。事前解析により得た処理のデータページ数の期待値と処理実行時の稼動統計情報を組み合わせることにより、問題と判断された処理や処理全体におけるキャッシュ量変更時の処理時間の変化を見積り、それを基に好適なキャッシュの割り当て方法を発見する。

### 【0104】

図22は、第四の実施形態による計算機システムの構成を示す図である。第四の実施における計算機システムの構成は、基本的に第一の実施の形態とものと似ている。以下、本実施の形態について、第一の実施形態との相違点を中心にして説明する。

### 【0105】

本実施の形態においては、記憶装置40がデータキャッシュ42における稼動統計情報を取得する記憶装置40dとなる。記憶装置40dにおいて、キャッシュグループにおけるキャッシュデータ置換制御は、それぞれ独立にLRU置換アルゴリズムを用いてわれる。前記アルゴリズムによるデータ置換によりデータキャッシュ42に存在しなくなったデータの記憶領域に関しても、データ置換後も一定量分は仮想管理領域としてLRU置換アルゴリズムの管理リスト中にその情報を記憶し、稼動状況の計測に利用する。制御プログラム44は、データキャッシュ42の稼動状況を計測し、管理情報46中にキャッシュモニタ情報362として保持する。このとき、LRU置換アルゴリズムのキャッシュセグメント（データキャッシュ42の領域管理単位）管理リストを等サイズの複数領域に分割し、分割領域毎にヒット数を計測する。更に、仮想管理領域に関しても実管理領域（実際にデータに対してキャッシュセグメントが割り当てられている領域）と等サイズの領域に分割して実管理領域と同様にヒット数を計測する。また、記憶装置40dは、外部からの要求に応じて、キャッシュモニタ情報362をネットワーク24を介して外部に送信する機能を有する。

### 【0106】

DBMS90は、メモリ14上の領域をキャッシュ94として利用するDBMS90dとなる。また、DBMS90dは、内部で利用されるソフトウェア機能や各データ構造のデータページ等の内部リソースに関して、それを利用する際に待ちが何回発生したかに関する稼動統計情報を収集し、それをDBMS管理情報92中にDBMSモニタ情報410として保持する。特に、本実施の形態においては、各データ構造毎にそのデータページを利用しようとした際に何回待ちが発生したかの累積値を保持する。

### 【0107】

サーバ70上では、DBMS90dの他にAPプログラム100が実行される。APプログラム100は、ユーザが行う業務のためにサーバ70上で実行されるプログラムであり、DBMS90dに対して処理要求を発行するものとする。APプログラム100は、HDD16もしくは記憶装置40からメモリ14に読み出されてCPU12により実行される。メモリ14上に読み込まれたAPプログラム100は、その管理情報であるAPプログラム管理情

報102を有する。

#### 【0108】

本実施の形態におけるAPプログラム100は、1つ以上の処理の組として実現され、それに処理ID 432が付加されている。ユーザはそのいずれかの処理実行を要求し、APプログラム100はそれに応じて処理を実施する。APプログラム100は受け付けた処理要求のキューイング制御を実施し、APプログラム100からDBMS90dに対して処理要求を発行した場合には、DBMS90dで即座に処理を開始できるものとする。APプログラム100は処理に関する実行統計情報を取得し、それをオンラインJobモニタ情報430としてAPプログラム管理情報102中に保持する。APプログラム100は、APプログラム管理情報102を外部プログラムが読むためのソフトウェアインターフェイスを有する。

#### 【0109】

DBMS90dとAPプログラム100が1台のサーバ70上で複数同時に実行されてもよい。また、DBMS90dとAPプログラム100が異なるサーバ70上で実行されてもよく、その場合には、APプログラム100はネットワーク24を経由してDBMS90dに処理要求を伝達する。

管理エージェント144がシステム管理プログラム140からの指示に従って実行する処理に、APプログラム管理情報102中に記憶されている情報の読み出しが加わる。

システム管理プログラム140は、システム管理情報142中に保持するDBMS情報420にデータ内部管理方法情報426を有する必要はない。その代わり、システム管理情報142中にHDD性能情報612を保持する。

#### 【0110】

図23は、キャッシュモニタ情報362のデータ構造を示す図である。

キャッシュモニタ情報362は、LU 208が外部装置からアクセスされた場合にどのキャッシュ領域にヒットしたかに関する稼動統計情報であり、実管理領域の分割数を示す実領域分割数502と、実管理領域の分割後のサイズを単位とした仮想管理領域の保持量を示す仮想管理領域数504を含む。また、LU 208毎のキャッシュヒット数の統計値として、LU ID 364を保持するエントリと、それに対応するリ

ード／ライトのI/O種別366を保持するエントリ、それに対応するI/O処理の累積実行回数368を保持するエントリ、そのときにヒットした回数を示すキャッシュヒット回数累計370を保持するエントリの組を保持する。なお、キャッシュヒット回数累計370は、実管理領域でのヒット数の総累計値と、実管理領域と仮想管理領域の双方で分割された各領域でのヒット数の累計値を保持する。本実施の形態では、実管理領域と仮想管理領域を統合して分割された領域に通番を付加し、最も最近利用されたデータが存在する領域を第1領域、以下小さい通番の領域ほど最近利用されたデータを有する領域であるとする。

#### 【0111】

図24は、DBMSモニタ情報410のデータ構造を示す図である。DBMSモニタ情報410は、ソフトウェア機能や各データ構造等の名前であるDBMSリソース名412を保持するエントリと、そのリソースを利用する際に発生した待ちの回数累積値である累積待ち回数414を保持するエントリの組を有する。

#### 【0112】

図25は、オンラインJob情報430のデータ構造を示す図である。オンラインJob情報430は、APプログラム100が取得する実行統計情報であり、処理ID 432を保持するエントリ、対応する処理の累積実行回数368を保持するエントリ、その処理をDBMS90dに対して発行した際の累積処理時間396（処理の待ち時間を含まない）を保持するエントリの組を有する。

#### 【0113】

図26は、HDD性能情報612のデータ構造を示す図である。HDD性能情報612はHDD16のアクセス性能に関する情報であり、記憶装置40dの識別子である装置ID 572を保持するエントリとHDD16の識別子であるHDD ID 394を保持するエントリ、それに対応するHDD16が有するアクセス性能に関する情報であるアクセス性能情報614を含むエントリの組を有する。アクセス性能情報614は、ランダムアクセス時のリードでキャッシュヒットした／しない（ミスした）場合、ライトでキャッシュヒットした／しない場合のそれぞれの平均応答時間を保持する。この情報は、記憶装置40dでのHDD16の型式を取得し、それと事前に与えられた型式毎の性能情報と組み合わせて作成する。

### 【0114】

以下、本実施の形態における、DBMS90dで実施される処理の設計情報と各要素の稼動統計情報と組み合わせたデータキャッシュ42のキャッシュ量チューニング処理の説明を行う。この処理は、システム管理プログラム140が行う。

### 【0115】

まず、システム管理プログラム140は、記憶装置40d、DBMS90d、APプログラム100から、それぞれキャッシュモニタ情報370、DBMSモニタ情報410、オンラインJobモニタ情報430（以下これらをまとめて「モニタ情報」と称す）を取得し、それを適当な形に編集した情報をシステム管理情報142中にモニタ履歴情報510として保持する。

### 【0116】

図27は、モニタ履歴情報510のデータ構造を示す図である。稼動状況がモニタされている部位（キャッシュモニタ情報362ではアクセス先のLU208も含む）に関して、システム内で一意に定まるモニタ部位ID 514が付加される。モニタ履歴情報510は、モニタ部位ID 514を保持するエントリとそのモニタ内容516を示す情報を保持するエントリと、対応する前回取得情報518を保持するエントリと、履歴情報520を保持するエントリの組を有する。

### 【0117】

モニタ内容516としては、モニタ情報のデータ構造を説明する際に説明した通りである。前回取得情報518は、前回モニタ情報の値を取得した日時のエントリとその取得値のエントリを有する。履歴情報520は、履歴として集計・記憶される値の内容を示す履歴内容522を保持するエントリと、ある期間のモニタ値であるサンプル524を保持する複数のエントリからなる。本実施の形態で利用する履歴内容522としては、キャッシュモニタ情報362からLU208におけるリード/ライト毎の平均実行回数と平均実ヒット率と、リードの領域毎の平均ヒット率（期間内の領域でのリードヒット回数/期間内のLU208へのリード実行回数）、DBMSモニタ情報410からとして各データ構造における平均待ち発生回数、オンラインJobモニタ情報430からとしてAPプログラム100における各処理毎の平均実行回数と平均処理時間がある。サンプル524は、そこに記憶されたデータがいつの期間のモニ

タ値かを示すエントリと、その期間における集計値である平均値と最大値をそれぞれ保持するエントリからなる。

#### 【0118】

モニタ履歴情報510への値の設定は以下のように行う。まず、システム管理プログラム140は、モニタ情報を取得している記憶装置40d、DBMS90d、APプログラム100からその値を一定間隔で取得する。データ取得後、対応する前回取得情報518のエントリ中に保存されている前回のデータ取得日時と取得値から、データの取得期間とその期間内の履歴内容522として指示される値を計算し、それをサンプル524に保存し、今回取得した値を対応する前回取得情報518に保存する。以下、これを繰り返す。なお、システム管理プログラム140は、連続した期間に対応するサンプル524の値をまとめたり、特に古い期間のデータを保持するサンプル524を削除する処理を適宜実施する。

#### 【0119】

以下、システム管理プログラム140により行われるデータキャッシュ量チューニング処理に関して説明する。この処理は、例えば、APプログラム100の平均応答時間が定められた値を下回った場合に実施され、基本的には、他の部位がボトルネックかどうかの確認を、別途取得している実行稼動統計情報を用いて行った後に、そのような部位が存在しない場合に実施される。

#### 【0120】

図28は、データキャッシュ量チューニングのメイン処理の処理フローである。外部からの指示に応じてこの処理は開始される。このとき、チューニング対象に関する情報として、対象となる処理が実施されているDBMS90dのDBMS ID 582と利用されるDBのDB ID 854、処理の事前解析結果として期待アクセスページ数情報780を与える。なお、期待アクセスページ数情報780の代わりに処理設計情報850を与え、それから第二の実施形態の場合と同様の方法で期待アクセスページ数情報780を求めてよい。また、期待アクセスページ数情報780中の期待アクセスページ数784は、各処理に求められるデータ整合性のレベルやデータのロック粒度から定まる、データへのロック取得方法の差を考慮して補正した値を用いても良い。（ステップ1801）

まず、DBMS90d内の各データ構造におけるデータページを利用しようとした際に、待ちが多数発生しているかを確認する。期待アクセスページ数情報780から処理に利用されるデータ構造を把握し、それらのデータ構造での平均待ち発生回数をモニタ履歴情報510中の履歴情報520の対応する最新の値を保持するエントリ524から把握し、あるデータ構造におけるその値が事前に定められている閾値以上の場合には、待ちが多数発生しているとしてステップ1803に進む。全てのデータ構造でその値が閾値未満の場合には、待ちが多数発生していないとしてステップ1811に進む。（ステップ1802）

ここでは、ステップ1802で待ちが多数発生していると判断されたデータ構造を利用する処理とそのデータ構造への期待アクセスページ数（総計値）を期待アクセスページ数情報780を参照して把握する。（ステップ1803）

続いて、ステップ1803で求めた処理の中で、処理時間が長く、かつ、待ちが多数発生しているデータ構造を多数回アクセスするものがないか確認する。処理における平均実行回数と平均処理時間をモニタ履歴情報510中の履歴情報520の対応する最新の値を保持するエントリ524から把握し、それらの値とステップ1803で求めたそのデータ構造への期待アクセスページ数との積をステップ1803で求めた処理に関して計算する。他の処理と比較したとき、常にその計算値が他の処理の値よりもある事前に定められた倍率（例えば4倍）となる処理が存在する場合に、その処理が、処理時間が長く、待ちが多数発生しているデータ構造を多数回利用する処理と判断し、ステップ1805に進む。そのような処理が存在しない場合にはステップ1811に進む。（ステップ1804）

ここでは、ステップ1804で求めた処理の処理時間が短くなるように、その処理が利用するデータのキャッシュヒット率を向上させるキャッシュ割当の変更方法を求める。ここでは、処理時間を短くしたい処理の処理ID 432を指定してステップ2701から開始される処理を実施する。（ステップ1805）

ここでは、各処理を全体としてみたときに処理時間の総和が小さくなるように、各処理が利用するデータのキャッシュヒット率を向上させるキャッシュ割当の変更方法を求める。ここでは、特に何も指定せずにステップ2701から開始される処理を実施する。（ステップ1811）

ステップ1805やステップ1811で求めたキャッシュ割当の変更方法に従って記憶装置40dにデータキャッシュ42の割当の変更を指示する。マッピング集約情報を参照し、処理で利用されるデータ構造のデータを保持するLU208とそれが属するキャッシュグループを把握し、そのキャッシュグループに対して求めたキャッシュ割当の変更方法に従ってキャッシュ量の変更指示を出す。なお、あるデータ構造のデータが異なるキャッシュグループに属する複数のLU208上に記憶される場合には、マッピング集約情報からそれぞれに記憶されているデータ量を把握し、それに比例するように割当の変更指示を出す。（ステップ1821）

ここで、処理を完了する。（ステップ1822）

図29は、モニタ情報を基にしたデータキャッシュ42の割当量をチューニングする処理の処理フローである。処理開始時に、特定の処理の処理時間を短くしたい場合には、その処理の処理ID 432が与えられる。それが与えられなかった場合には、各処理全体として処理時間を短くするとする。なお、本処理はステップ1801から始まる処理の一部であり、その処理が利用可能な情報は全て利用できる。（ステップ2701）

まず、期待アクセスページ数情報780とマッピング集約情報を参照し、処理が利用するデータ構造を保持する記憶装置40d、LU208、キャッシュグループと、そのキャッシュグループにおけるデータキャッシュ42の割当量を各処理毎に求める。（ステップ2702）

続いて、キャッシュ量を変更した際のキャッシュヒット率の変化量を計算する。ここで、記憶装置40dにおける実領域分割数502と仮想管理領域数504の値がそれぞれRとVであるとする。LU208が属するキャッシュグループの現在のキャッシュ量をCとしたとき、キャッシュモニタ情報362中のキャッシュヒット回数累計370における第i領域( $0 < i \leq R$ )のヒット数は、そのLU208が属するキャッシュグループのキャッシュ量を $iC/R$ から $(i-1)C/R$ に削減したときにヒットしなくなる回数、第i領域( $R < i \leq R+V$ )のヒット数は、キャッシュ量を $(i-1)C/R$ から $iC/R$ に増加させたときにヒットするようになる回数と考えられる。キャッシュ量をCから $C/R$ 減らしたときの平均実ヒット率の削減分が第R領域における平均ヒット率であるから、LU208におけるキャッシュ量が $(i-1)C/R$ から $iC/R$ の範囲( $0 < i \leq R$ )での単位キャ

カッシュ量あたりの平均ヒット率削減分は(第*i*領域での平均ヒット率) × R/Cとして近似可能である。同様に、キャッシュ量が(i-1)C/RからiC/Rの範囲(R < i <= R+V)での単位キャッシュ量あたりの平均ヒット率增加分は(第*i*領域での平均ヒット率) × R/Cとして近似可能である。なお、各LU208毎のリードアクセス実行時の第*i*領域(0 < i <= R+V)での平均ヒット率はモニタ履歴情報510に保持されている。記憶装置40dにおける実領域分割数502と仮想管理領域数504は記憶装置40dのキャッシュモニタ情報362中に保持されているものを記憶装置40dから取得することができる。

### 【0121】

この値を各処理が利用するデータ構造を保持するLU208について全て計算し、ヒット率変化率とする。なお、以下のステップを含めてモニタ履歴情報510からは最も直近のサンプル524による値、もしくは、事前に定められた直近のある期間の平均値を取得するものとする。(ステップ2703)

次に、マッピング集約情報を用いて、各処理が利用するデータ構造を保持するLU208に対応するHDD16を把握する。そして、HDD性能情報612のHDD16のアクセス性能情報614を参照してHDD16のリードヒット時の平均応答時間とリードミス時の平均応答時間を求め、(リードミス時の平均応答時間)-(リードヒット時の平均応答時間)を計算しLU208の応答時間変化量とする。なお、LU208中のデータが性能の異なるHDD16に分割されて記憶される場合には、HDD16毎に応答時間変化量を求め、HDD16に記憶されるデータ量で重み付き平均を計算した値をLU208の応答時間変化量とする。(ステップ2704)

記憶装置40d毎に、

$$I = \Sigma (\text{LU処理時間変化の平均}) \quad \text{ただし、} \quad (\text{LU処理時間変化の平均}) = (\text{応答時間変化量}) \times (\text{LUの平均リードI/O回数}) \times (\text{ヒット率変化量})$$

の値を増加させるようにキャッシュ割当の変更方法を求める。応答時間変化量はステップ2704で求めたものを用いる。ヒット率変化量はステップ2703で求めたヒット率変化率とキャッシュ割当の変更量から求めることができる。このとき、ヒット率変化率は、キャッシュグループのキャッシュ量により変化することに注意する。

### 【0122】

各処理全体の処理時間を考慮し、それを短くする（処理開始時に特定の処理ID 432が与えられなかった）場合、 $\Sigma$ は、記憶装置40dにおいて各処理が利用するデータ構造を保持するLU208に関して総和を取ることを意味する。LU208の平均リードI/O回数はモニタ履歴情報510から取得可能であり、取得値をそのまま用いる。

### 【0123】

処理時間を短くしたい処理の処理ID 432が与えられた場合には、 $\Sigma$ は、記憶装置40dにおいて指定処理が利用するデータ構造を保持するLU208に関して総和を取ることを意味する。LU208の平均リードI/O回数は、指定処理への寄与分のみを考える。各処理によるLU208へのリード処理回数は、処理における期待アクセスページ数情報780中の期待アクセステータページ数784の総計値に比例しているとして指定処理に関連するリードI/Oの割合を計算し、モニタ履歴情報510から取得した平均リードI/O回数にその割合を乗じた値をIの計算に用いる。

### 【0124】

Iを用いたキャッシュ割当の変更方法決定には、例えば以下のアルゴリズムを用いる。まず、各処理が利用するデータ構造を保持するLU208が属するキャッシュグループに対して、単位キャッシュ量を増やした場合と減らした場合のIを計算する。そして、キャッシュ量を減らした場合に最もIが大きい（影響が小さい）キャッシュグループから最もIの値が大きい（効果が高い）キャッシュグループへ単位量分キャッシュ割当を変更したとした場合のIの値を計算し、それがある閾値以上のときに効果ありとしてキャッシュ割当の変更を行うとする。なお、処理時間を短くしたい処理の処理ID 432が与えられた場合には、上記で求めたキャッシュ割当の変更により、各処理全体の処理時間を考慮した場合のIの値の変化も同時に確認し、その値が別の0以下のある閾値より小さい（処理全体として処理時間が悪化する）場合には、そのキャッシュ割当の変更は不可として別のキャッシュ割当変更方法を求める。

### 【0125】

以下、キャッシュ割当の変更が行われたとして上記確認を繰り返し実施し、更

に割当変更を行うことに効果なしと判断されるか、もしくは、事前に定められる量（例えば、記憶装置40dで利用しているキャッシュ量の一定割合）の割当変更を行った場合に、この確認の繰り返しを終了させる。（ステップ2705）

そして、処理を完了する。（ステップ2706）

これまで、記憶装置40dはLU208を外部装置に提供し、それはI/Oバス34を経由してアクセスされるとしてきた。第一の実施の形態と同様に、記憶装置40dがファイル202を外部装置に提供し、そのファイル202がネットワークファイルシステムプロトコルを用いてネットワーク24経由でアクセスされてもよい。この場合、第一の実施の形態と同様の対応関係がとられる。

#### 【0126】

主要な相違点としては、記憶装置40dでは、キャッシュグループのメンバの管理単位がファイル202単位となり、本実施の形態における処理においては、LU208の部分が記憶装置40d上のファイル202に対応するようになる。

#### 【0127】

##### 【発明の効果】

本発明によれば、DBMSが稼動する計算機システムにおいて、データの利用目的や処理内容から生じるデータの特性を考慮したキャッシュ量の設定を行うことができる。これにより記憶装置のデータキャッシュが一層有効に活用され、好適な性能を得ることができる。

また、記憶装置のキャッシュ量の設定やそのチューニングを自動的に行うことができ、計算機システムの性能管理コストが削減される。

##### 【図面の簡単な説明】

##### 【図1】

第一の実施の形態による計算機システムの構成を示す。

##### 【図2】

第一の実施の形態におけるデータマッピングの階層構成の概念を示す。

##### 【図3】

領域マッピング情報300のデータ構造を示す。

##### 【図4】

キャッシュグループ情報460のデータ構造を示す。

【図5】

データ記憶領域情報342のデータ構造を示す。

【図6】

属性サイズ情報350のデータ構造を示す。

【図7】

DBMS情報420のデータ構造を示す。

【図8】

処理設計情報850のデータ構造を示す。

【図9】

ログのキャッシュ量を定める処理の処理フローを示す。

【図10】

第一の実施の形態の変形例を説明に供する計算機システムの構成を示す。

【図11】

第二の実施の形態による計算機システムの構成を示す。

【図12】

キャッシュ化要求954とキャッシュ化要求付ライト要求958を用いた際の、DBMS 90bと記憶装置40bとの間のデータ制御を示す。

【図13】

キャッシュグループ情報460bのデータ構造を示す。

【図14】

表データ量情報700のデータ構造を示す。

【図15】

B-Tree索引情報710のデータ構造を示す。

【図16】

キャッシュ量情報720のデータ構造を示す。

【図17】

表アクセス分布情報730のデータ構造を示す。

【図18】

期待アクセスページ数情報780のデータ構造を示す。

【図19】

第二の実施の形態による、DBMS90b及び記憶装置40bにおけるキャッシュ量を設定する処理の処理フローを示す。

【図20】

キャッシュ効果関数を利用してキャッシュ量の割り当てを行う処理の処理フローを示す。

【図21】

第三の実施の形態による、DBMS90cや記憶装置40におけるキャッシュ量を設定する処理の処理フローを示す。

【図22】

第四の実施の形態による計算機システムの構成を示す。

【図23】

キャッシュモニタ情報362のデータ構造を示す。

【図24】

DBMSモニタ情報410のデータ構造を示す。

【図25】

オンラインJob情報430のデータ構造を示す。

【図26】

HDD性能情報612のデータ構造を示す。

【図27】

モニタ履歴情報510のデータ構造を示す。

【図28】

データキャッシュ量チューニングのメイン処理の処理フローを示す。

【図29】

モニタ情報を基にしたデータキャッシュ42の割当量をチューニングする処理の処理フローを示す。

【符号の説明】

16…HDD、


22…ネットワークI/F、

24…ネットワーク、 32…I/OバスI/F、  
34…I/Oバス、 40、40b、40d…記憶装置、  
60、60b…仮想化スイッチ、 70…サーバ、  
90、90b、90c、90d…DBMS、 100…APプログラム、  
120…管理サーバ、 140…システム管理プログラム

【書類名】 図面


【図 1】

図 1




【図 2】

図 2



【図 3】

図 3



【図 4】

図 4

キャッシュグループ ID	CGrp0	CGrp1	...
キャッシュ量	1024MB	2048MB	...
LU ID	LU 0, LU 2, LU 3, ...	LU 1	...

キャッシュグループ情報

Arrows point from the table rows to the right with labels: 462, 466, 364, and 460.

【図 5】

図 5

図 5 の構成要素：

- 346：データ構造名
- 348：データ記憶位置
- 342：データ記憶領域情報

データ記憶位置のデータ：

データ構造名	データファイルパス名	ブロック番号
T1	/dev/rdsk/lvol0	0 - 499
	/dev/rdsk/lvol0	2000 - 2499
T2	/dev/rdsk/lvol0	500 - 799
T3	/dev/rdsk/lvol1	500 - 799
⋮	⋮	⋮

【図 6】

図 6

図 6 の構成要素：


- 346：データ構造名
- 352：属性名
- 354：最大サイズ
- 350：属性サイズ情報

属性サイズ情報のデータ：

データ構造名	属性名	最大サイズ
T1	ID1	12 Byte
	ID2	10 Byte
⋮	⋮	⋮
T2	ID2	10 Byte
⋮	⋮	⋮

【図 7】

図 7



【図 8】

図 8

Diagram illustrating the structure of processing design information (処理設計情報). The main structure is a rectangular box divided into several sections:

- Top section: DBMS ID: DBMS4, DB ID: DB8, Re-Run性能: 100件/s, Re-Run最大所要時間: 30秒.
- Middle section: A table with columns for 处理ID, 実行比率, 実行SQL文, and 期待回数. It contains three rows of data:
 

処理ID	実行比率	実行SQL文	期待回数
1	0.3	SELECT T1.ID1, T2.ID2 FROM T1, T2, T3 WHERE ... FOR UPDATE;  UPDATE T4 SET att3 = :input WHERE ...;	1
2	0.25	SELECT T3.att3, T4.att2 FROM T3, T4 WHERE ...;	2.8
:	:	:	:
- Bottom section: A summary section labeled 850.

Wavy lines on the left side point to specific fields in the middle section:


- Line 582 points to the first column of the middle section.
- Line 854 points to the second column of the middle section.
- Line 856 points to the third column of the middle section.
- Line 432 points to the first column of the middle section.
- Line 862 points to the second column of the middle section.
- Line 860 points to the third column of the middle section.

Wavy lines on the right side point to specific fields in the middle section:

- Line 858 points to the fourth column of the middle section.
- Line 864 points to the fourth column of the middle section.


## 【図9】

図 9




【図 10】

図 10




## 【図 11】

図 11



【図 12】

図 12



## 【図 13】

図 13

キャッシュグループ ID	CGrp0	CGrp1	...	462
キャッシュ量	1024MB	2048MB	...	466
LU ID	LU 0, LU 2, LU 3, ...	LU 1	...	364
ヒント機能	OFF	ON	...	468

キャッシュグループ情報  
460b

## 【図 14】

図 14

データ構造名	T1	T2	...	346
データページサイズ	16kB	8kB	...	702
データページ数	61897	78783	...	704
キャッシュ量	1024ページ	2048ページ	...	466

表データ量情報  
700


【図15】

図 15

データ構造名	Ind1-1	Ind2-1	...	346
対応表名	T1	T2	...	712
データページサイズ	8kB	8kB	...	702
データページ数	3782	6782	...	704
Leafノードページ数	2898	4890	...	714
キャッシュ量	1452ページ	2400ページ	...	466
検索属性	ID1	(ID1,ID2)	ID2	716
期待タプル数	5.5	1	1	718
B-Tree索引情報				


【図16】

図 16



【図17】

図 17



【図 18】


図 18

処理ID	データ構造名	期待アクセスデータページ数	
		総計	更新
1	T1	9	6
	Ind1-1	9	0
	T2	1	1
	⋮	⋮	⋮
2	T3	4	0
	⋮	⋮	⋮
	⋮	⋮	⋮

期待アクセスページ数情報


【図19】

図 19




## 【図20】

図 20




【図21】

図 21



【図 22】

図 22



【図 23】

図 23

This diagram shows a table titled 'キャッシュモニタ情報' (Cache Monitor Information) with various columns and rows. The table includes sections for LU ID, I/O種別 (I/O Type), 累積実行回数 (Cumulative Execution Count), and a detailed section for 'キャッシュヒット回数累計' (Cache Hit Count Cumulative). The table is labeled with numbers 502, 504, 364, 366, 368, 370, and 362, which likely correspond to specific fields or annotations in the original document.

実管理領域分割数: R		仮想管理領域数: V			
LU ID	LU 0	LU 1	...		
I/O種別	Read	Write	Read	Write	...
累積実行回数	489789	78978	168799	789	...
実ヒット総計	138978	78978	48958	789	...
第1領域	0	-	342	-	...
第2領域	2870	-	6869	-	...
:	:	:	:	:	:
第V+R領域	7987	-	4789	-	...

キャッシュモニタ情報

【図 24】

図 24

This diagram shows a table titled 'DBMSモニタ情報' (DBMS Monitor Information) with columns for DBMSリソース名 (DBMS Resource Name) and 累積待ち回数 (Cumulative Wait Count). The table is labeled with numbers 412, 414, and 410, which likely correspond to specific fields or annotations in the original document.

DBMSリソース名	Log Writer	Dic	Tbl1	...
累積待ち回数	7809	36	0	...

DBMSモニタ情報

【図25】

図 25

オンラインJobモニタ情報

処理ID	1	2	...
累積実行回数	48978	7897	...
累積処理時間	102956	24637	...

【図26】

図 26

HDD性能情報

装置ID	Storage 0		...	
HDD ID	HDD0, HDD1, ...		...	
アクセス 性能情報	リードヒット	0.8	0.8	...
	リードミス	5.5	8	...
	ライトヒット	1.2	1.2	...
	ライトミス	12	17	...

【図 27】


図 27

The diagram shows a table structure for monitoring history information. The table has several rows and columns, with some rows having rowspan attributes. Callout numbers (510 to 524) point to specific parts of the table.

モニタ履歴情報						
モニタ部位ID		Host0-Port 0	Host0-Port 0	...	514	
モニタ内容		累積実行回数	累積データ転送量	...	516	
前回 収集 情報	日時	'02/12/14 13:00:00	'02/12/14 13:00:00	...	518	
	収集値	7907209	50298237893	...		
履歴内容		平均IOPS	平均データ転送量(MB/s)	...	522	
履歴 情報	サンプル 0	期間	'02/12/1 00:00:00～ 00:05:00	'02/12/1 00:00:00～ 00:05:00	...	524
		平均	152	7.6	...	
		最大	203	10.2	...	
	サンプル 1	期間	'02/12/1 00:05:00～ 00:10:00	'02/12/1 00:05:00～ 00:10:00	...	520
		平均	189	9.5	...	
		最大	258	12.9	...	
	⋮	⋮	⋮	⋮	⋮	510


【図28】

図 28



【図 29】

図 29



【書類名】 要約書

【要約】

【課題】

データベース管理システム(DBMS)が稼動する計算機システムにおける記憶装置のキャッシュ量の設定を好適化する。

【解決手段】

設計情報として与えられるDBMSで実施される処理に関する情報を取得し、それを基にデータ毎に利用するキャッシュ量を設定する。例えば、DBMSの異常終了後の処理の再実行時間を考慮して、DBMSが書き出すログに対するキャッシュ量を調整する。また他の例では、処理内容とデータのおよそのアクセス特性から、表・索引データに対するキャッシュ量の初期割り当てを好適化する。更に他の例では、処理の事前解析結果と稼動統計情報と組み合わせてキャッシュ量チューニングによる処理時間の変化を見積り、キャッシュ効果を向上させる。

【選択図】 図1

特願 2003-090360

出願人履歴情報

識別番号

[000005108]

1. 変更年月日

1990年 8月31日

[変更理由]

新規登録

住 所

東京都千代田区神田駿河台4丁目6番地

氏 名

株式会社日立製作所